

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Dinko Dujmić

Zagreb, 2014.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Mentor:

Izv. prof. dr. sc. Goran Đukić, dipl. ing.

Student:

Dinko Dujmić

Zagreb, 2014.

Izjavljujem da sam ovaj rad izradio samostalno koristeći stečena znanja tijekom studija i navedenu literaturu.

Zahvaljujem se svojem mentoru, prof. dr. sc. Goranu Đukiću na pruženoj pomoći i podršci tijekom izrade ovog diplomskog rada. Zahvaljujem se također prof. dr. sc. Dragutinu Lisjaku na danoj literaturi koja mi je pomogla u izradi ovog rada.

Dinko Dujmić



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za diplomske ispite studija strojarstva za smjerove:
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment, inženjerstvo
materijala i mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa:	
Ur.broj:	

DIPLOMSKI ZADATAK

Student:

Dinko Dujmić

Mat. br.: 0035167464

Naslov rada na
hrvatskom jeziku:

Primjena višekriterijalnog odlučivanja u odabiru lokacije skladišta

Naslov rada na
engleskom jeziku:

**Application of multi criteria decision making in warehouse location
problem**

Opis zadatka:

U odabiru lokacije skladišta relevantni su brojni različiti kriteriji, kvantitativni i kvalitativni, od kojih mnogi i međusobno suprotstavljeni. S obzirom da su razvijene brojne metode višekriterijalnog odlučivanja, kao i pripadajući alati, za spomenuti problem određivanja optimalne lokacije skladišta moguće je primjeniti neku od tih metoda.

U radu je potrebno:

- Pojasniti problem i značaj određivanja optimalne lokacije skladišta.
- Shodno literaturnim izvorima napraviti pregled brojnih kriterija koji se mogu uzeti u obzir prilikom određivanja optimalne lokacije skladišta.
- Ilustrirati razlike u pristupu rješavanja problema kvantitativnim modelima i rješavanja višekriterijalnim odlučivanjem.
- Napraviti pregled metoda višekriterijalnog odlučivanja.
- Za odabranu metodu AHP (Analytical Hierarchy Process) detaljnije prikazati način rješavanja, te opisati raspoloživi softverski alat Expert Choice.
- Na odabranom primjeru odabira optimalne lokacije skladišta ilustrirati primjenu AHP metode primjenom softverskog alata.

Zadatak zadan:

25. rujna 2014.

Rok predaje rada:

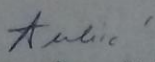
27. studenog 2014.

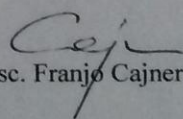
Predviđeni datum obrane:

3., 4. i 5. prosinca 2014.

Zadatak zadao:

Predsjednik Povjerenstva:


Izv.prof. dr.sc. Goran Đukić


Prof. dr. sc. Franjo Cajner

SADRŽAJ

SADRŽAJ	1
POPIS SLIKA	3
POPIS TABLICA.....	4
SAŽETAK.....	5
SUMMARY	6
1. UVOD.....	7
2. PROBLEM LOKACIJE SKLADIŠTA	9
2.1. Definicija.....	9
2.2. Važni kriteriji u određivanju lokacije skladišta	10
2.2.1. Troškovi	14
2.2.1.1. Troškovi rada	14
2.2.1.2. Transportni troškovi.....	15
2.2.1.3. Troškovi rukovanja	15
2.2.1.4. Cijena zemljišta.....	15
2.2.2. Karakteristike radnika	15
2.2.2.1. Kvalificiranost radnika.....	15
2.2.2.2. Dostupnost radnika	15
2.2.3. Geografski položaj	15
2.2.3.1. Dostupnost zemljišta.....	15
2.2.3.2. Klima.....	16
2.2.4. Infrastruktura.....	16
2.2.4.1. Prometna povezanost	16
2.2.4.2. Telekomunikacijski sustav	16
2.2.4.3. Kvaliteta i pouzdanost prometnih veza.....	16
2.2.4.4. Kvaliteta i pouzdanost komunalnih usluga	16
2.2.5. Tržište	16
2.2.5.1. Udaljenost kupaca.....	17
2.2.5.2. Udaljenost dobavljača ili proizvođača	17
2.2.5.3. Vodeće vrijeme i odziv	17
2.2.6. Makrookruženje	17
2.2.6.1. Politika vlade	17
2.2.6.2. Zakonske regulative u industriji.....	17
2.2.6.3. Prostorno uređenje i gradnja	17
2.2.7. Ekonomski faktori.....	17
2.2.7.1. Porezni propisi i poticaji	17
2.2.7.2. Financijski poticaji.....	17
2.3. Kvantitativni modeli i metode u primjeni rješavanja problema lokacije skladišta	18
2.3.1. Transportni model	19
2.3.2. Minimaks model	19
2.3.3. Medijan metoda	20
2.3.4. Gravitacijska metoda	22
2.4. Višekriterijalno odlučivanje u primjeni rješavanja problema lokacije skladišta	23

3. VIŠEKRITERIJALNO ODLUČIVANJE	24
3.1. Prikaz	24
3.2. Pregled metoda.....	26
3.2.1. AHP.....	27
3.2.2. ELECTRE.....	28
3.2.3. TOPSIS	28
3.2.4. PROMETHEE.....	29
3.2.5. Grey theory	30
4. AHP METODA	31
4.1. Definicija.....	31
4.2. Struktura i način funkcioniranja.....	31
4.3. Konzistentnost.....	33
4.4. AHP na primjeru odabira lokacije skladišta	35
4.4.1. Strukturiranje problema [18].....	35
4.4.2. Određivanje najznačajnijeg kriterija [18]	36
4.4.2.1. Definicija matrice odlučivanja	36
4.4.2.2. Množenje matrice odlučivanja	39
4.4.2.3. Određivanje 1. vektora prioriteta (eigenvector).....	41
4.4.2.4. Množenje matrice odlučivanja	42
4.4.2.5. Određivanje 2. vektora prioriteta (eigenvector).....	44
4.4.2.6. Određivanje najznačajnijeg kriterija	45
4.4.3. Određivanje najznačajnije alternative [18]	45
4.4.3.1. Cijena ($\text{€}/\text{m}^2$).....	45
4.4.3.2. Kapacitet skladišta (jedinice).....	46
4.4.3.3. Prosječna udaljenost od trgovina (km)	46
4.4.3.4. Prosječna udaljenost od dobavljača (km)	47
4.4.3.5. Fleksibilnost kretanja (0-4)	47
4.4.4. Određivanje konačnog rješenja [18]	47
4.4.5. Provjera konzistentnosti [18]	48
4.5. Softverski alat expert choice 11 za rješavanje problema AHP metodom	49
5. ODABIR LOKACIJE SKLADIŠTA PRIMJENOM AHP METODE U EXPERT CHOICE-u	50
6. ANALIZA OSJETLJIVOSTI REZULTATA	69
7. ZAKLJUČAK.....	73
LITERATURA.....	75
PRILOZI.....	77

POPIS SLIKA

Slika 1.	Pregled kriterija i potkriterija za određivanje lokacije skladišta [2]	11
Slika 2.	Pregled kriterija i raznih potkriterija za određivanje lokacije skladišta na područjima prirodnih katastrofa [6]	13
Slika 3.	Pregled kriterija i potkriterija za određivanje lokacije skladišta humanitarne pomoći [7]	14
Slika 4.	Pregled važnih kriterija za određivanje optimalne lokacije skladišta [3].....	18
Slika 5.	Hijerarhijski pregled metoda višekriterijalnog odlučivanja [9]	27
Slika 6.	Hijerarhijska struktura AHP modela s kriterijima i alternativama.....	32
Slika 7.	Saatyjeva skala prioriteta [18]	33
Slika 8.	Primjer konzistentnosti [18]	34
Slika 9.	Hijerarhijska struktura problema [5]	36
Slika 10.	Prikaz usporedbi na Saatyjevoj skali	37
Slika 11.	Logo softverskog alata expert choice [19]	49
Slika 12.	Struktura problema s kriterijima i alternativama.....	50
Slika 13.	Usporedba kriterija u parovima prema Saatyjevoj skali	51
Slika 14.	Usporedba kriterija u parovima prema Saatyjevoj skali s obzirom na važnost.....	52
Slika 15.	Usporedba kriterija u parovima s obzirom na grafički prikaz.....	52
Slika 16.	Usporedba alternativa u parovima s obzirom na cijenu	53
Slika 17.	Usporedba alternativa u parovima s obzirom na cijenu, nakon invertiranja	54
Slika 18.	Usporedba alternativa u parovima s obzirom na kapacitet skladišta.....	55
Slika 19.	Usporedba alternativa u parovima s obzirom na prosječnu udaljenost od trgovina	56
Slika 20.	Usporedba alternativa u parovima s obzirom na prosječnu udaljenost od trgovina, nakon invertiranja.....	57
Slika 21.	Usporedba alternativa u parovima s obzirom na prosječnu udaljenost od glavnih dobavljača.....	58
Slika 22.	Usporedba alternativa u parovima s obzirom na prosječnu udaljenost od glavnih dobavljača, nakon invertiranja	59
Slika 23.	Usporedba alternativa u parovima s obzirom na fleksibilnost kretanja	60
Slika 24.	Definiranje formule direktnog unosa podataka	61
Slika 25.	Unos normaliziranih vrijednosti podataka	61
Slika 26.	Relativne važnosti (težine) kriterija	62
Slika 27.	Prioriteti alternativa s obzirom na cijenu	62
Slika 28.	Prioriteti alternativa s obzirom na kapacitet skladišta.....	63
Slika 29.	Prioriteti alternativa s obzirom na prosječnu udaljenost od trgovina.....	63
Slika 30.	Prioriteti alternativa s obzirom na prosječnu udaljenost od glavnih dobavljača ...	64
Slika 31.	Prioriteti alternativa s obzirom na fleksibilnost kretanja.....	64
Slika 32.	Ukupni prioriteti alternativa (idealni način)	65
Slika 33.	Ukupni prioriteti alternativa (distributivni način)	65
Slika 34.	Prioriteti alternativa u 2D grafu.....	66
Slika 35.	Graf usporedbe skladišta D i skladišta A	67
Slika 36.	Graf usporedbe skladišta D i skladišta B.....	68
Slika 37.	Graf usporedbe skladišta D i skladišta C.....	68
Slika 38.	Graf dinamičnosti	70
Slika 39.	Graf performansi	71
Slika 40.	Graf gradijenta s obzirom na prosječnu udaljenost od trgovina.....	72

POPIS TABLICA

Tablica 1. Vrijednosti RI slučajnih indeksa [15].....	34
Tablica 2. Primjer odabira lokacije skladišta [5].....	35
Tablica 3. Matrica odlučivanja	38
Tablica 4. Matrica odlučivanja nakon prvog množenja	40
Tablica 5. Matrica odlučivanja nakon drugog množenja	43
Tablica 6. Rangiranje ukupnih prioriteta alternativa ovisno o metodi [5]	69

SAŽETAK

Odabir lokacije skladišta je problem višekriterijalnog odlučivanja koji uključuje kvalitativne i kvantitativne kriterije, a ima stratešku važnost za mnoge kompanije.

U prvom dijelu rada prikazana je važnost i problematika određivanja lokacije skladišta. Prezentiran je sistematizirani pregled kriterija i potkriterija koji su relevantni pri određivanju lokacije skladišta, ali i dani neki konkretni primjeri. Pojašnjena je razlika u pristupu rješavanja problema lokacije skladišta kvantitativnim modelima i višekriterijalnim odlučivanjem. Kod kvantitativnih modela objašnjena je pomoć transportnog i minimaks modela te medijan i gravitacijske metode pri određivanju lokacije skladišta.

U drugom dijelu rada objašnjen je pojam višekriterijalnog odlučivanja i dan prikaz raznih metoda koje su našle svoju primjenu. Za metode višekriterijalnog odlučivanja koje su upotrijebljene pri odabiru lokacije skladišta ili distribucijskog centra (AHP, ELECTRE, TOPSIS, PROMETHEE i *grey theory*) dan je kratak opis.

U zadnjem dijelu rada, za odabranu AHP metodu dan je detaljan opis i prikaz načina rješavanja na primjeru odabira lokacije skladišta. Opisan je raspoloživi softverski alat *expert choice* te je identičan primjer riješen primjenom istog. Dobiveni rezultati su komentirani i uspoređeni s rezultatima iz znanstvenog članka.

Ključne riječi: problem lokacije skladišta, višekriterijalno odlučivanje, AHP, expert choice

SUMMARY

Warehouse location selection is a multi criteria decision making problem including qualitative and quantitative criteria, and has a strategic importance for many companies.

In the first part issue of warehouse location selection is described. Criteria and sub-criteria that can be relevant in warehouse location selection are proposed. Some examples of determined criteria for warehouse location selection are given. Difference between quantitative models and multi criteria decision making is shown. The use of transportation model, minimax model, median method and gravity method in warehouse location selection is explained.

In the second part multi criteria decision making is explained and some methods are shown. Multi criteria decision making methods that have been used in warehouse or distribution center location selection (AHP, ELECTRE, TOPSIS, PROMETHEE and grey theory) are briefly described.

In the last part, for selected AHP method detailed description and procedure on example of warehouse location selection is given. Expert choice software for AHP method is described. The same example of warehouse location selection is solved using expert choice. The obtained results are discussed and compared with results from scientific paper.

Key words: warehouse location problem, multi criteria decision making, AHP, expert choice

1. UVOD

Skladište je komercijalna građevina za skladištenje robe s namjerom da poslije određenog vremena roba bude uključena u daljnji transport, proizvodnju, distribuciju ili potrošnju. Skladišta predstavljaju ključni aspekt u modernim lancima opskrbe i imaju važnu ulogu u uspjehu, odnosno neuspjehu kompanija. Lokacija skladišta bitna je za: proizvođače, uvoznike, izvoznike, trgovce, transportne tvrtke, itd.

Odabir lokacije skladišta predstavlja jednu od najvažnijih odluka u optimizaciji logističkih sustava. To je dugoročna odluka koja se donosi pod utjecajem brojnih kvalitativnih i kvantitativnih kriterija. U takvim slučajevima kvantitativni modeli i metode ne pomažu, obzirom da oni razmatraju samo jedan kriterij, najčešće smanjenje prijednog puta odnosno troškova transporta. Kao jedino rješenje među brojnim kriterijima, od kojih su mnogi međusobno suprotstavljeni, nude se razne metode višekriterijalnog odlučivanja.

Višekriterijalno odlučivanje se koristi kao snažna tehnika u donošenju odluke, a pronalazi svoju primjenu u: vrednovanju rada zaposlenika, procjeni zdravstvene zaštite u postupanju s otpadom, određivanju bankarske učinkovitosti, internet bankarstvu, određivanju najboljih profesora, odabiru dobavljača, upravljanjem lancem opskrbe, odabiru lokacije skladišta, itd. U nekim primjerima, pojavljuje se određena nesigurnost u odlučivanju, pa se koristi tzv. *fuzzy* višekriterijalno odlučivanje.

Metode višekriterijalnog odlučivanja koje pronalaze svoju primjenu u određivanju lokacije skladišta ili distribucijskog centra su: AHP, *fuzzy* AHP, ELECTRE, TOPSIS, *fuzzy* TOPSIS, PROMETHEE i *grey theory*.

AHP metoda spada u najpoznatije i posljednjih godina najkorištenije metode za višekriterijalno odlučivanje. Metodu svojstvenog vektora razvio je Thomas L. Saaty početkom 1970-ih, a njezina popularnost proizlazi iz činjenice da je vrlo bliska načinu na koji pojedinac rješava složene probleme, rastavljajući ih na jednostavnije komponente: cilj, kriterije i alternative. Te se komponente povezuju u model u kojemu je na najvišoj razini cilj, na prvoj nižoj razini se nalaze kriteriji i njihovi potkriteriji, a na najnižoj razini su alternative (mogućnosti).

U ovom diplomskom radu detaljno se objašnjava algoritam AHP metode na primjeru odabira lokacije skladišta, preuzetom iz znanstvenog članka [5]. Osim klasičnog proračuna, primjer se obrađuje u raspoloživom softverskom alatu *expert choice*, te se rezultati uspoređuju

s rezultatima iz znanstvenog članka koji su dobiveni metodama: TOPSIS, ELECTRE i *grey theory*. Također se prikazuje analiza osjetljivosti rezultata u kojoj se pokušava dočarati koliko promjene relativnih važnosti (težina) kriterija utječu na ukupne prioritete alternativa, odnosno rezultate dobivene AHP metodom.

2. PROBLEM LOKACIJE SKLADIŠTA

2.1. Definicija

Problem lokacije skladišta obuhvaća utvrđivanje lokacije jednog ili više skladišta na jednom ili više potencijalnih mjesta. Očigledno, broj potencijalnih mjesta mora biti jednak ili veći od broja novih skladišta koja se planiraju izgraditi [1].

Optimalna lokacija skladišta ima važnu ulogu u optimizaciji logističkih sustava. Efikasno kretanje robe od izvora sirovina do pogona za obradu, pogona za proizvodnju dijelova, pogona za završnu montažu, distribucijskih centara, skladišta, trgovaca i kupaca je kritično u današnjem konkurentskom okruženju. Logistika i upravljanje lancima opskrbe u današnjem svijetu koji se brzo razvija, postaju sve važniji [2].

Lokacija skladišta je generalno jedna od najvažnijih strateških odluka u optimizaciji logističkih sustava. To je dugoročna odluka koja nastaje pod utjecajem brojnih kvalitativnih i kvantitativnih kriterija. Ipak, neki kriteriji su toliko važni da imaju tendenciju da dominiraju i prevagnu u odluci [3].

Pretpostavlja se da su troškovi lokacije novog skladišta na potencijalnim lokacijama unaprijed poznati. To su fiksni troškovi izgradnje novog skladišta na određenoj lokaciji sumirani s operativnim i transportnim troškovima. Operativni i transportni troškovi su varijabilni, a proizlaze iz posluživanja kupaca odnosno opskrbljivanja trgovina s određene potencijalne lokacije na kojoj bi se nalazilo skladište [1].

Teorija određivanja lokacije je prvi put predstavljena od strane Alfreda Webera 1909. godine koji je razmatrao problem određivanja lokacije jednog skladišta kako bi se minimizirao ukupni prijeđeni put između skladišta i skupa prostorno raspoređenih kupaca. On je predložio indeks prema kojem se određivala lokacija skladišta. Ako je indeks bio veći od jedan, lokacija skladišta bi trebala biti u blizini izvora sirovina, u suprotnom skladište bi se nalazilo u blizini tržišta [4].

Osim problema lokacije (*location problem*) pojavljuje se i problem raspoređivanja (*allocation problem*) skladišta. Pretpostavlja se da je broj i lokacija skladišta poznata unaprijed i pokušava se utvrditi kako će svaki kupac biti poslužen. Drugim riječima, problem raspoređivanja utvrđuje koliko će svako skladište dostaviti pojedinom trgovačkom centru, obzirom na potražnju robe u svakom trgovačkom centru odnosno trgovini, kapacitete opskrbe svakog skladišta i troškove usluživanja svakog kupca iz pojedinog skladišta [1].

Pored ova dva postoji još i problem lokacije i raspodjele (*location-allocation problem*) skladišta. On ne samo da utvrđuje koliko će svaki kupac dobiti robe iz pojedinog skladišta već i broj skladišta zajedno s njihovim lokacijama i kapacitetima [1].

Problem lokacije skladišta može se podijeliti na problem lokacije jednog skladišta (*single-facility problem*) i problem lokacije više (*multifacility problem*) skladišta. Kao što ime kaže, problem lokacije jednog skladišta bavi se optimalnom odlukom lokacije jednog skladišta, dok se problem lokacije više skladišta bavi s odlukom istovremene lokacije više od jednog skladišta. Generalno, problem lokacije jednog skladišta je zapravo problem lokacije skladišta, dok problem lokacije više skladišta može biti problem lokacije skladišta ili problem lokacije i raspoređivanja skladišta [1]. S obzirom na jednostavnost kao i obujam ovog diplomskog rada, daljnji rad bavit će se uglavnom problemom lokacije jednog skladišta.

Osim gornje podjele, problem lokacije skladišta se dijeli prema tome da li je skup mogućih lokacija skladišta ograničen ili beskonačan. Ako se skladište može smjestiti bilo gdje unutar granica zemljopisnog područja, onda je broj mogućih lokacija beskonačan i takav problem se naziva problem kontinuirane lokacije (*continuous space location problem*). Suprotno njemu, problem diskretne lokacije (*discrete space location problem*) ima ograničena mjesta na kojima se može smjestiti skladište. Problem kontinuirane lokacije pretpostavlja da su troškovi transporta proporcionalni udaljenosti. S obzirom na to da se skladište može smjestiti bilo gdje u dvodimenzionalnom prostoru, ponekad optimalna lokacija dobivena od modela kontinuirane lokacije može biti neizvediva. Na primjer, model kontinuirane lokacije može smjestiti skladište na sredini jezera! Zbog toga, za većinu realnih problema, modeli diskretne lokacije su prikladniji za korištenje [1].

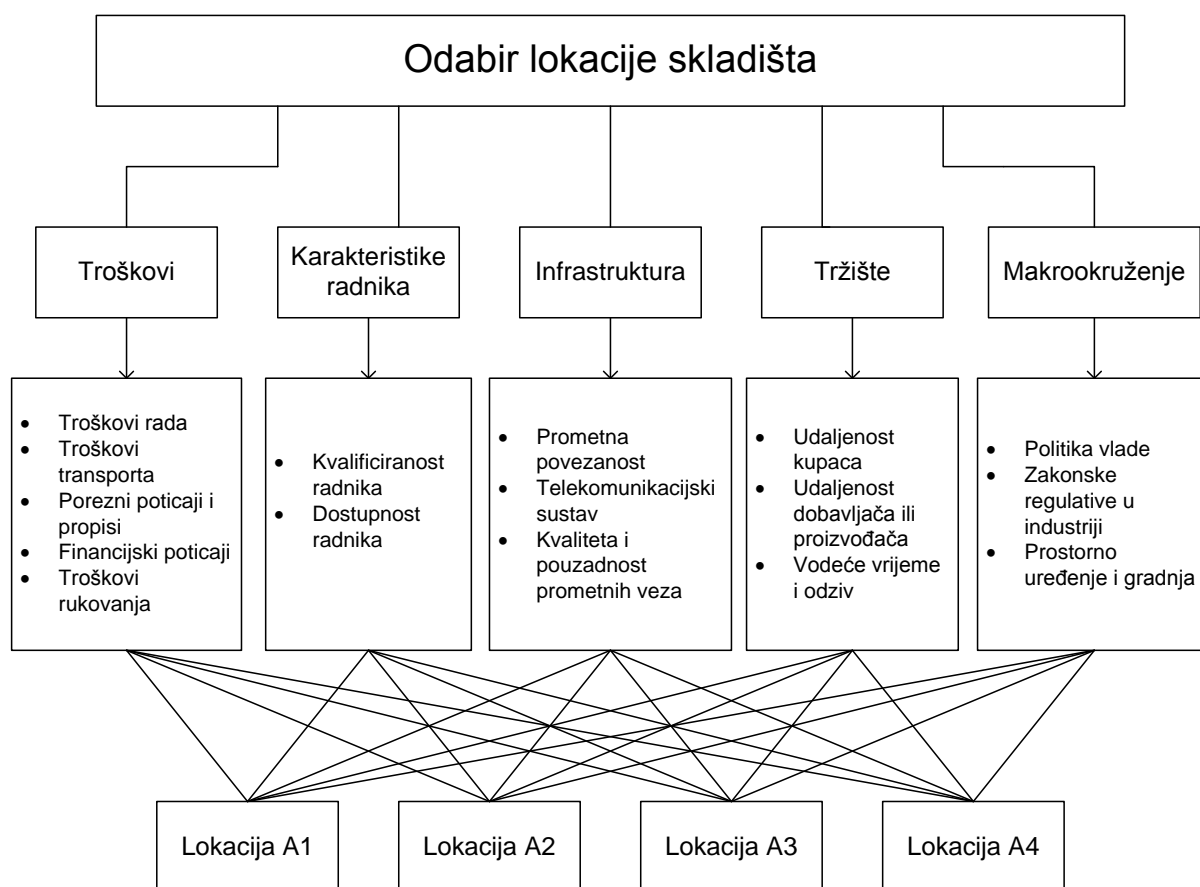
2.2. Važni kriteriji u određivanju lokacije skladišta

U praksi, mnogi faktori imaju utjecaj na određivanje lokacije skladišta. Relativna važnost ovih faktora ovisi o tome da li je područje određenog problema lokacije skladišta međunarodno, državno ili samo u određenoj općini. Na primjer, ako se želi odrediti lokacija skladišta u stranoj državi, faktori kao što su politička stabilnost, devizni tečaj, poslovna klima, carine, trošarine, pristojbe i porezi igraju veliku ulogu. Ako je pak područje lokacije skladišta ograničeno na par općina, onda faktori poput rada za opće dobro, poreznih poticaja na nekretnine, lokalne poslovne klime i lokalnih propisa su puno važniji [1].

Kriteriji u određivanju lokacije skladišta razlikuju se od slučaja do slučaja, ovisno o državi ili tipu industrije. Heragu [1] u svojoj knjizi navodi neke od najvažnijih kriterija u

određivanju lokacije skladišta ili proizvodnog pogona: udaljenost izvora sirovine; dostupnost i troškovi energije; dostupnost, vještine, produktivnost i troškovi radno sposobnog stanovništva; vladini propisi na svim razinama; porezi na svim razinama; osiguranje; cijene zemljišta i troškovi izgradnje; politička stabilnost; promjene tečaja; pravila uvoza i izvoza, carine, trošarine i ostale pristojbe; transportni sustav; tehnička stručnost; propisi zaštite okoliša; službe za podršku; rad za opće dobro; vrijeme; udaljenost kupaca; poslovna klima; uvjeti tržišnog natjecanja.

Za problem lokacije skladišta u Turskoj, Demirel i sur. [2] odredili su 5 glavnih kriterija: troškovi, karakteristike rada, infrastruktura, tržište i makrookruženje. Osim ovih glavnih kriterija definiraju i razne potkriterije [Slika 1].



Slika 1. Pregled kriterija i potkriterija za određivanje lokacije skladišta [2]

Ozcan i sur. [5] za određivanje lokacije skladišta predstavili su 5 kriterija: cijena, kapacitet skladišta, prosječna udaljenost od trgovina, prosječna udaljenost od dobavljača, fleksibilnost kretanja.

Degener i sur. [6] u studiji određivanja lokacije skladišta na područjima prirodnih katastrofa, odredili su 7 glavnih kriterija: troškovi, vrijeme dostave, prostorna udaljenost,

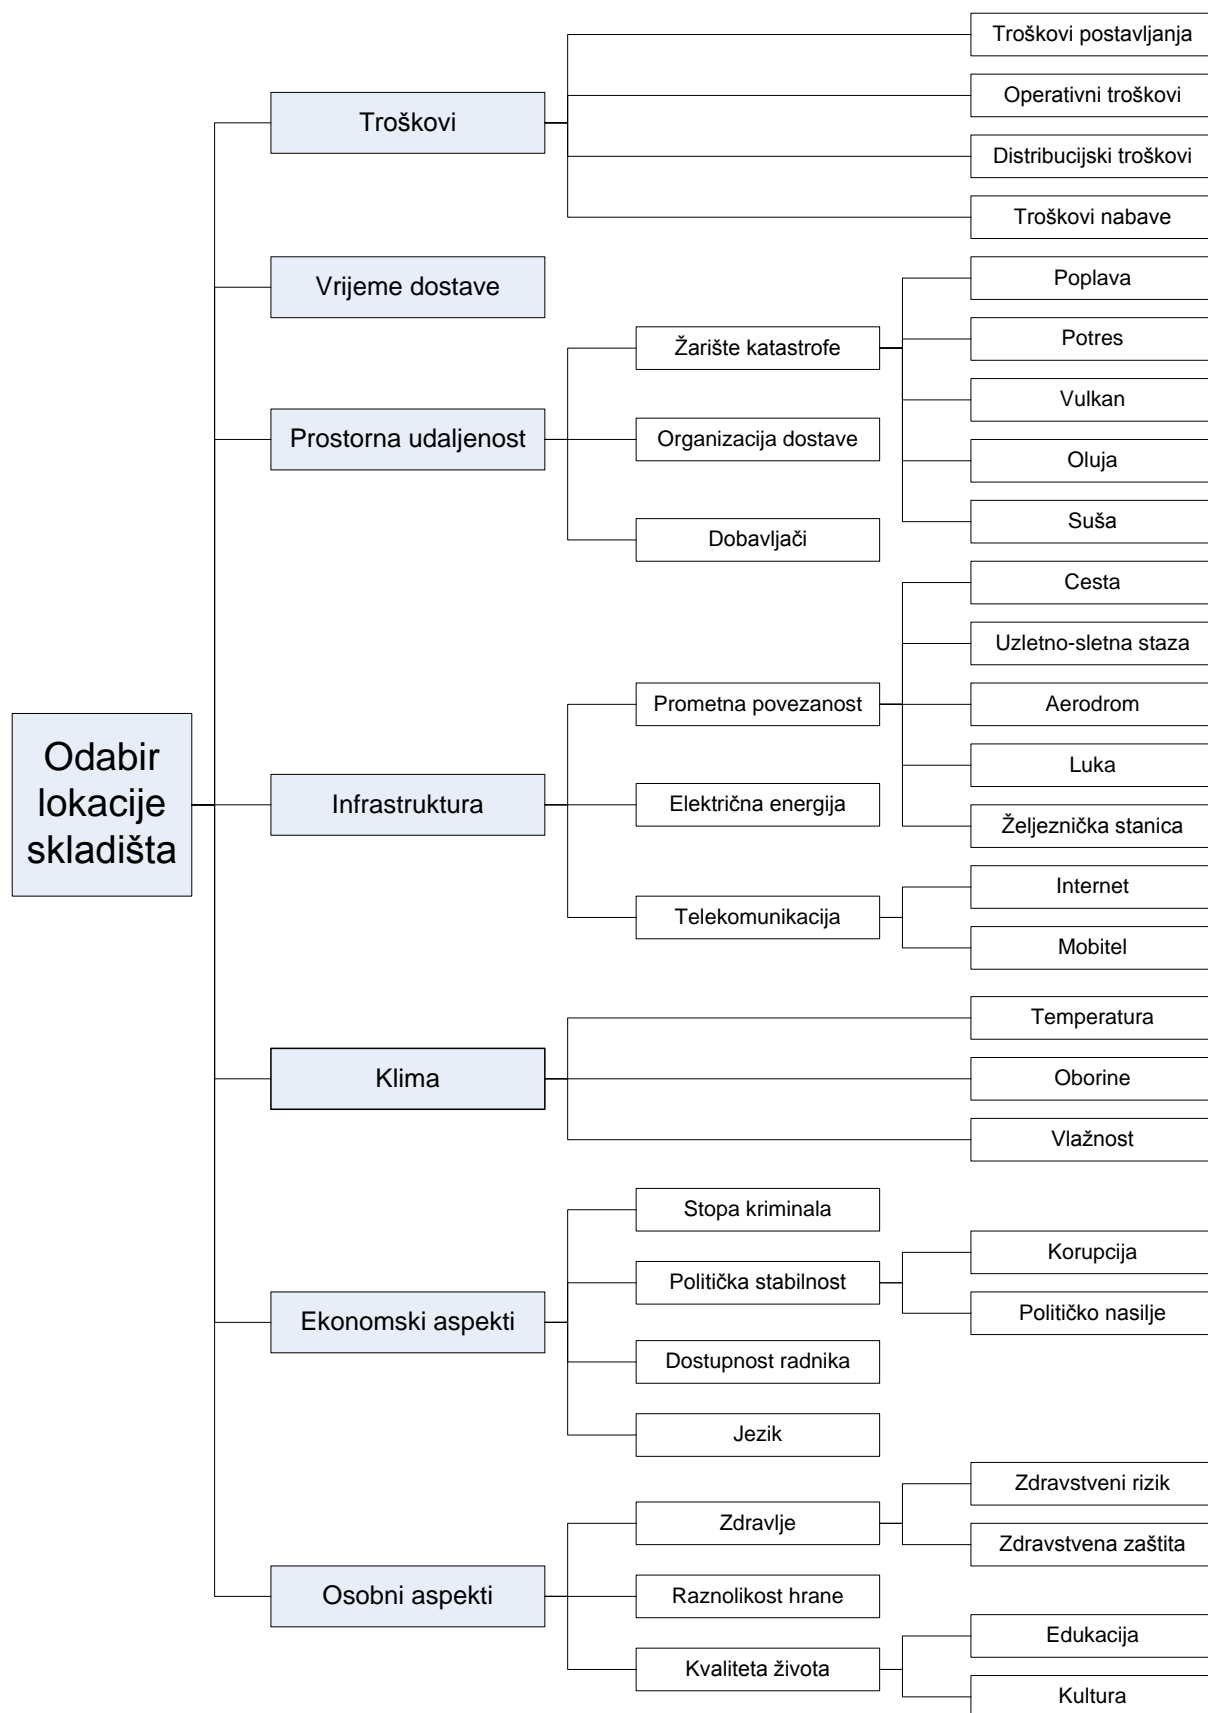
infrastruktura, klima, ekonomski aspekti, osobni aspekti. Pored nabrojanih glavnih kriterija definirali su i brojne potkriterije [Slika 2].

U studiji određivanja lokacije skladišta humanitarne pomoći, Roh i sur. [7] izabrali su 5 glavnih kriterija: lokacija, logistika, nacionalna stabilnost, troškovi, kooperacija. Osim navedenih kriterija, odredili su razne potkriterije [Slika 3].

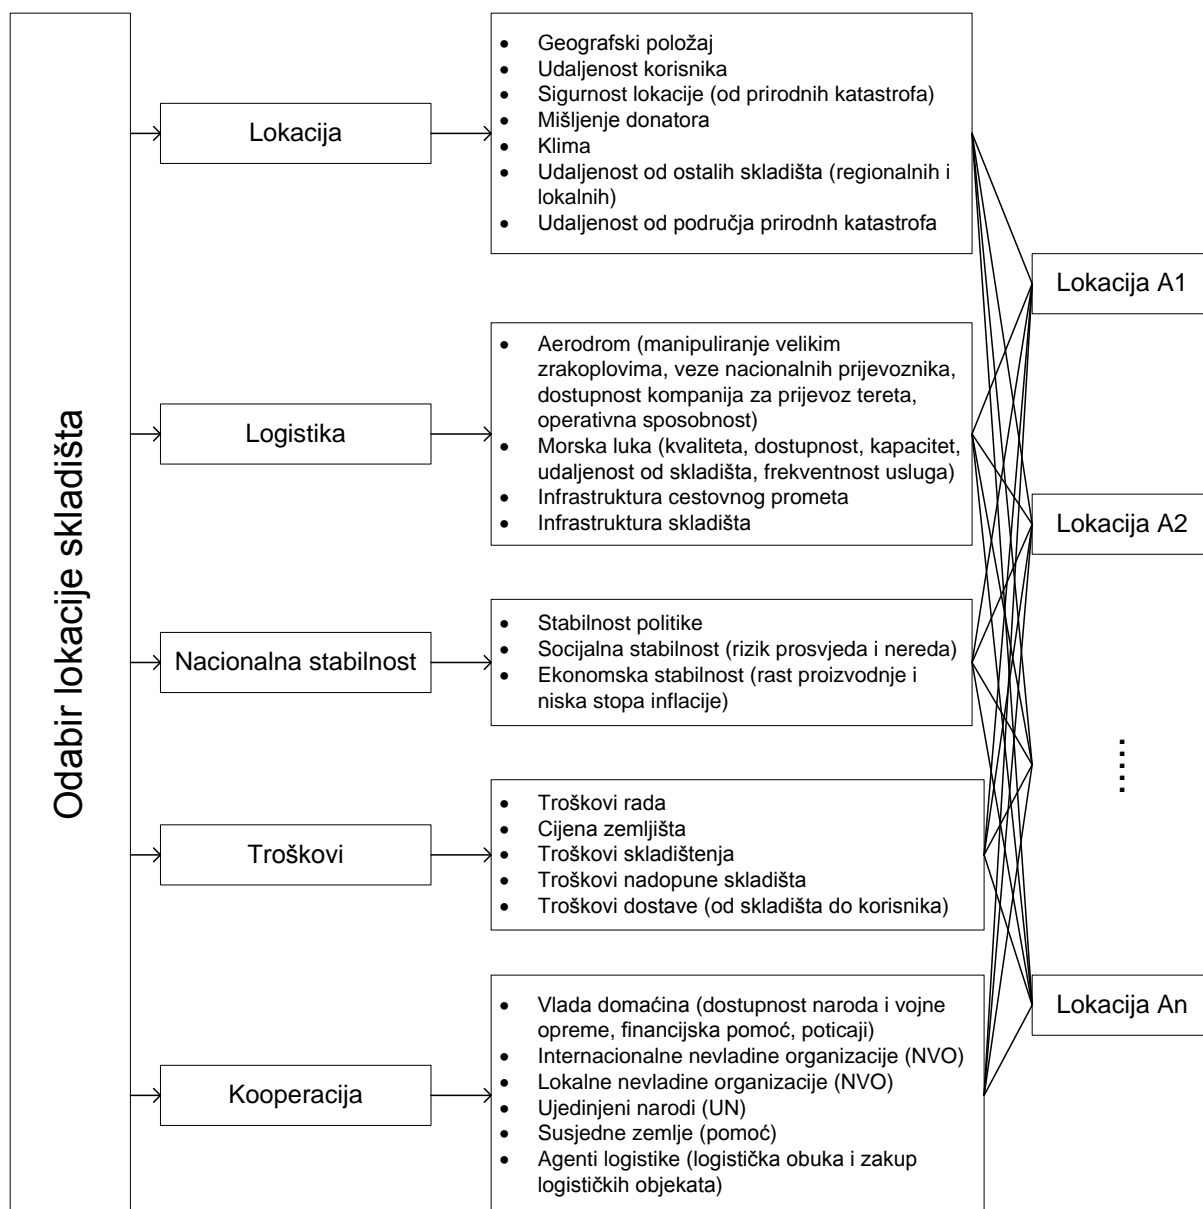
Awasthi i sur. [8] za izbor lokacije urbanog distribucijskog centra odredili su 11 kriterija: pristupačnost, sigurnost, prometna povezanost, troškovi, utjecaj na okoliš, udaljenost kupaca, udaljenost dobavljača, dostupnost izvora sirovina i radnika, usklađenost s teretnim propisima, mogućnost proširenja, kvaliteta usluge.

Često je jako teško pronaći optimalnu lokaciju koja zadovoljava sve ove kriterije u željenom pogledu. Na primjer, jedna lokacija će zadovoljiti uvjet visoko obrazovnog stanovništva ali će cijena zemljišta i izgradnje biti previsoka. Druga lokacija će ponuditi niske poreze i minimalne vladine propise ali će biti previše udaljena od baze kupaca ili izvora sirovina. Prema tome, problem lokacije skladišta je zapravo odabir jedne od nekoliko ponuđenih alternativa, koja ima težinski optimalan skup ciljeva [1].

Problem određivanja lokacije skladišta može se pristupiti iz makro ili mikro perspektive. Glavne odrednice za određivanje lokacije mogu se primjeniti na međunarodni, regionalni ili neki specifični problem [7]. Proučavanjem prethodno navedenih studija, utvrđeno je da osim glavnih kriterija, u većini slučajeva postoji još i niz potkriterija. Teško je odlučiti koji kriteriji su najvažniji, obzirom da su u svim studijama navedeni različiti kriteriji. Međutim, shodno literaturnim izvorima, u dva općenita studija slučaja daje se pregled važnih kriterija i potkriterija koji se mogu uzeti u obzir prilikom određivanja optimalne lokacije skladišta.



Slika 2. Pregled kriterija i raznih potkriterija za određivanje lokacije skladišta na područjima prirodnih katastrofa [6]



Slika 3. Pregled kriterija i potkriterija za određivanje lokacije skladišta humanitarne pomoći [7]

2.2.1. Troškovi

Troškovi su jedan od kriterija koji najviše utječe na odabir lokacije skladišta. U troškove spadaju četiri potkriterija.

2.2.1.1. Troškovi rada

Ovi troškovi se razlikuju s obzirom na uvjete življenja na različitim lokacijama.

2.2.1.2. Transportni troškovi

Transportni troškovi se razlikuju prema ekonomskoj strukturi različitih regija, prometnicama i vrsti prijevoza, na primjer: zrakom, cestom, željeznicom i morem.

2.2.1.3. Troškovi rukovanja

Troškovi rukovanja sastoje se od: opreme, kapitala, radne moći, rizičnih troškova. Uzrokovani su skladištenjem robe te variraju od regije do regije.

2.2.1.4. Cijena zemljišta

Cijena zemljišta se jako razlikuje po regijama, a smatra se jednim od najskupljih elemenata u odabiru lokacije skladišta.

2.2.2. Karakteristike radnika

Ovaj kriterij definira kvalificiranost i dostupnost radne snage na pojedinim lokacijama.

2.2.2.1. Kvalificiranost radnika

Kvalificiranost radnog stanovništva definira idealan izbor kadrova potrebnih za posao, kao što su oni koji imaju kvalifikaciju ali i stručno iskustvo. Ovo je jedan od zahtjeva kojeg je potrebno ispuniti kako bi se posao obavio na kvalificirani način, unutar traženog vremena, ispunjavajući visoku razinu standarda. Kvalificirano radno stanovništvo možda neće biti dostupno na svakoj lokaciji.

2.2.2.2. Dostupnost radnika

Dostupnost radnog stanovništva je kriterij koji se mijenja s obzirom na stupanj razvoja u regiji, razinu obuke i strukturu stanovništva.

2.2.3. Geografski položaj

Ovaj kriterij uključuje dostupnost zemljišta i klimu.

2.2.3.1. Dostupnost zemljišta

Dostupnost zemljišta se mijenja ovisno o strukturi alternativnih regija.

2.2.3.2. *Klima*

Utjecaj klime varira od regije do regije. Značajne klimatske promjene i teški vremenski uvjeti ometaju poslovanje, ali i utječu na učinkovitost radnika.

2.2.4. *Infrastruktura*

Infrastruktura definira osnovnu strukturu prijevoza i sustav komunikacije s obzirom na lokaciju skladišta. Ovaj kriterij se sastoji od četiri potkriterija: prometna povezanost, telekomunikacija, kvaliteta i pouzdanost prometnih veza, kvaliteta i pouzdanost komunalnih usluga.

2.2.4.1. *Prometna povezanost*

S obzirom na različite načine transporta, što bolja prometna povezanost na odabranoj lokaciji ima važan utjecaj.

2.2.4.2. *Telekomunikacijski sustav*

Sustav telekomunikacije je kriterij koji definira komunikacijske sadržaje i tehnologije koje su dostupne na određenoj lokaciji, a služi za komunikaciju skladišta s kupcima, proizvođačima ili dobavljačima.

2.2.4.3. *Kvaliteta i pouzdanost prometnih veza*

S obzirom na različite načine transporta, što veća kvaliteta i pouzdanost prometnih veza vrlo je bitna, kako bi se mogao odviti pouzdan i kvalitetan transport robe između kupaca, dobavljača i skladišta. Pouzdana i kvalitetna usluga predstavlja isporuku neoštećene robe u pravo vrijeme na pravom mjestu.

2.2.4.4. *Kvaliteta i pouzdanost komunalnih usluga*

Kvaliteta i pouzdanost komunalnih usluga se smatra kriterijem koji se razlikuje od regije do regije.

2.2.5. *Tržište*

Ovaj kriterij definira udaljenost lokacije skladišta od kupaca, dobavljača i proizvođača.

2.2.5.1. *Udaljenost kupaca*

Udaljenost kupaca definira udaljenost lokacije skladišta od kupaca.

2.2.5.2. *Udaljenost dobavljača ili proizvođača*

Ovaj kriterij definira udaljenost lokacije skladišta od dobavljača i proizvođača.

2.2.5.3. *Vodeće vrijeme i odziv*

Vodeće vrijeme i odziv definiraju sposobnost i period koji je potreban za ispunjenje zahtjeva narudžbe.

2.2.6. ***Makrookruženje***

Ovaj kriterij uključuje vladinu politiku, industrijske dogovore i regulative te razvojne planove regije na makro razini.

2.2.6.1. *Politika vlade*

Politika vlade se razlikuje od jednog do drugog područja, a paralelna je s razvijenošću regije. Sadrži faktore kao što su različiti poticaji, porezne olakšice i investicijske pogodnosti.

2.2.6.2. *Zakonske regulative u industriji*

Zakonske regulative u industriji su različiti zakoni i zakonske regulative a paralelni su s politikom i administracijom lokalnih uprava.

2.2.6.3. *Prostorno uređenje i gradnja*

Ovim kriterijem se definiraju prostorni planovi općina i uvjeti gradnje.

2.2.7. ***Ekonomski faktori***

Ekonomski faktori uključuju porezne propise i poticaje te financijske poticaje.

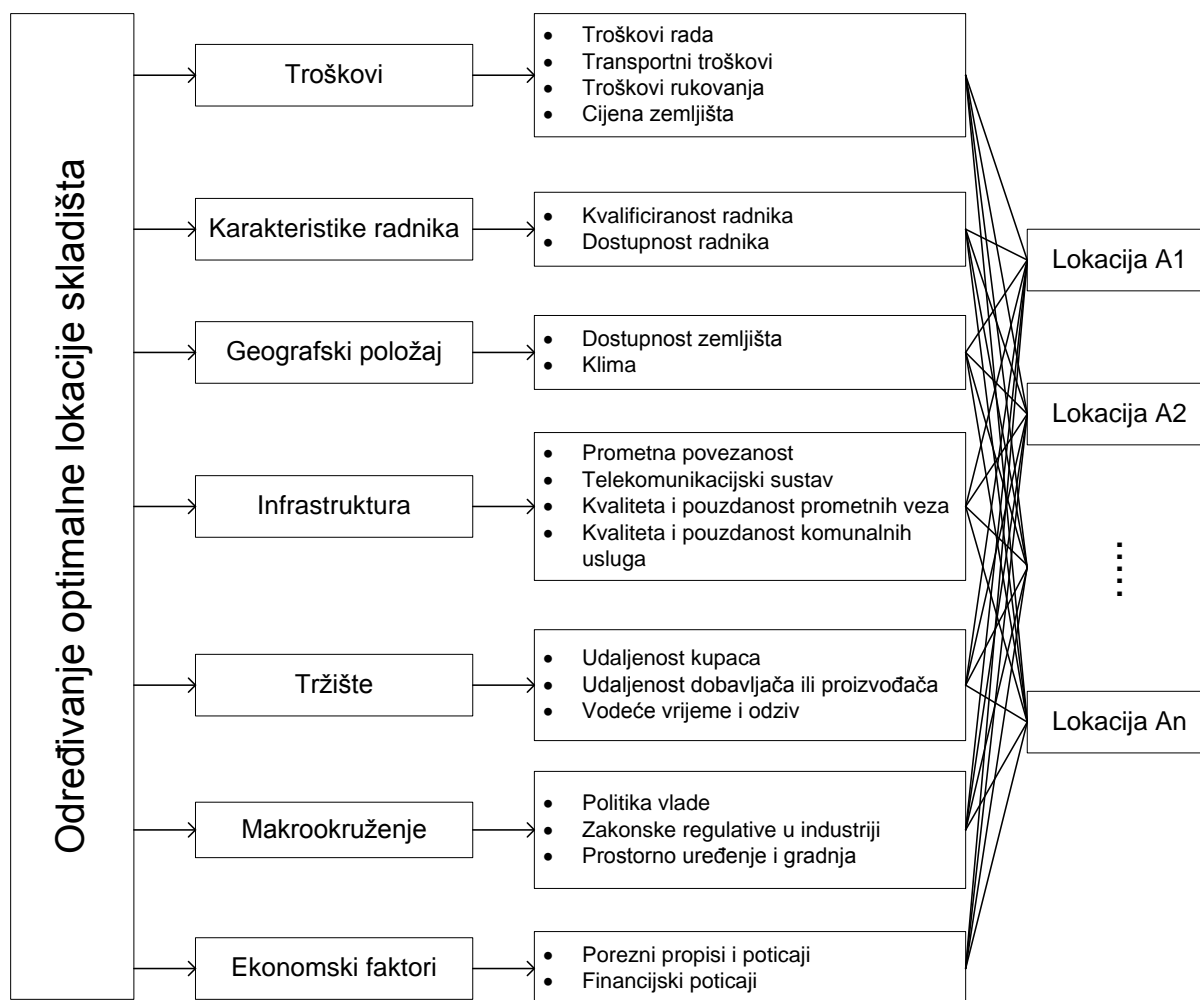
2.2.7.1. *Porezni propisi i poticaji*

Porezni poticaji i propisi se razlikuju ovisno o regijama koje imaju prioritet u razvoju.

2.2.7.2. *Financijski poticaji*

Financijski poticaju su zapravo kreditni poticaji od privatnih ili državnih banaka koji se ostvaruju u pojedinim regijama.

Slika 4. prikazuje strukturirani problem odabira lokacije skladišta s obzirom na navedene kriterije i potkriterije. Na najvišoj razini prikazuje se ultimativni cilj problema koji je odabir optimalne lokacije skladišta. Druga razina hijerarhije grupira se u sedam glavnih kriterija. Na trećoj razini, glavni kriteriji se dijele na nekoliko potkriterija koji mogu utjecati na odabir optimalne lokacije skladišta. Na donjoj razini hijerarhije nalaze se alternative.



Slika 4. Pregled važnih kriterija za određivanje optimalne lokacije skladišta [3]

2.3. Kvantitativni modeli i metode u primjeni rješavanja problema lokacije skladišta

Ovi modeli i metode služe kao pomoć pri rješavanju problema lokacije jednog skladišta, a imaju uglavnom jedan cilj (kriterij), smanjiti prijedeni put (troškove transporta) između skladišta i trgovina (proizvodnih pogona). Ovisno o tome da li je broj mogućih lokacija unutar određenog zemljopisnog područja ograničen ili beskonačan, postoje tehnike određivanja diskretne lokacije i kontinuirane lokacije. Transportni model i minimaks model

spadaju u tehnike određivanja diskretne lokacije. Ako je došlo do povećanja potražnje kupaca u logističkom lancu, a samim time i potrebe za otvaranjem novog skladišta, pri određivanju lokacije koristit će se transportni model, kako bi se smanjili ukupni troškovi transporta. Ako je pak cilj minimizirati maksimalnu udaljenost do svakog korisnika, odnosno odrediti lokaciju skladišta do koje će sve postojeće trgovine imati minimalnu najveću udaljenost, koristit će se minimaks model. Pored tehnika određivanja diskretne lokacije, postoje i tehnike određivanja kontinuirane lokacije, u koje spadaju medijan metoda i gravitacijska metoda. Ove metode se koriste pri određivanju lokacije skladišta koje će primati robu iz nekoliko tvornica s poznatim lokacijama, gdje je cilj smanjiti ukupne troškove interakcije između istih. Medijan metoda se koristi kao pomoć pri rješavanju problema s pravocrtnom udaljenošću dok se gravitacijska metoda koristi pri rješavanju problema s kvadratnom euklidskom udaljenošću. Osim navedenih postoje još i *contour line method* te *weiszfeld method*.

2.3.1. Transportni model

Transportni model spada u tehnike određivanja diskretne lokacije, a prikladan je za određivanje lokacije tvornice ili skladišta gdje je cilj smanjiti ukupni prijedan put općenito. Ovaj model se najviše koristi za određivanje optimalne distribucije robe između postojećih skladišta i poznatih kupaca, kao i za smanjenje ukupnih troškova transporta robe između skladišta i kupaca, zadovoljavajući pritom zahtjeve kupaca i ograničenja opskrbe skladišta. Na primjer, postoji m skladišta u distribucijskoj mreži koja posluži n kupaca. S obzirom na povećanje potražnje jednog ili više kupaca, postalo je nužno otvoriti još jedno skladište kako bi se ispunili zahtjevi kupaca. Novo skladište se može smjestiti na p mogućih lokacija. Kako bi se odredilo koja od p lokacija će minimizirati troškove transporta (distribucije), može se postaviti p transportnih modela, svaki s n kupaca i $m+1$ skladišta, gdje ovo $m+1$ skladište odgovara novoj lokaciji koja se određuje. Rješavanje modela daje odgovor na transport robe između $m+1$ skladišta (uključujući novo skladište s lokacije koja se određuje), ali i troškove transporta. Lokacija koja donosi najmanji ukupni trošak transporta je lokacija na kojoj bi novo skladište trebalo biti smješteno [1].

2.3.2. Minimaks model

Minimaks model (*minimax model*) spada u tehnike određivanja diskretne lokacije, a prikladan je za određivanje lokacije hitnih službi (policije, vatrogasaca, hitne medicinske pomoći), gdje je cilj minimizirati maksimalnu udaljenost (troškove) do svakog korisnika, ali

se može koristiti i u određivanju lokacije skladišta. Ovaj problem se može riješiti trivijalno, uvidom u troškove ili prijedeni put. Na primjer, razmatra se problem lokacije vatrogasne stanice u nekoj županiji. Pretpostavlja se da ima m mogućih lokacija i da se županija, obzirom na populaciju stanovništva, može podijeliti na n područja. Udaljenosti između središta svakog n područja i m moguće lokacije vatrogasne stanice, dane su u matrici:

$$\begin{array}{c} \text{Lokacija} \end{array} \begin{array}{c} \text{Područje} \\ \left[\begin{array}{cccc} d_{11} & d_{12} & \cdots & d_{1n} \\ d_{21} & d_{22} & \cdots & d_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ d_{m1} & d_{m2} & \cdots & d_{mn} \end{array} \right] \end{array} \quad (1)$$

Kako bi se pronašla optimalna lokacija, jednostavno treba pregledati svaki redak zbog maksimalne udaljenosti i izabrati područje koje odgovara retku, koji ima najmanju maksimalnu udaljenost. Ta lokacija će osigurati da maksimalna udaljenost koju svaki korisnik mora prijeći, bude minimalna [1].

2.3.3. Medijan metoda

Medijan metoda (*median method*) spada u tehnike određivanja kontinuirane lokacije. Kao što i samo ime kaže, medijan metoda pronalazi lokaciju medijana i dodjeljuje ju novom skladištu. Ova metoda se koristi za problem lokacije jednog skladišta s pravocrtnom udaljenošću. Ako se uzme u obzir da postoji m skladišta u distribucijskoj mreži. Zbog tržišnih razloga (npr. povećana potražnja kupaca), poželjno je dodati još jedno skladište u ovu mrežu. Pretpostavlja se da je interakcija između novog skladišta i ostalih poznata. Problem se pojavljuje kod određivanja lokacije novog skladišta.

Iz makro perspektive, ovaj problem se pojavljuje kod određivanja lokacije skladišta koje će primati robu iz nekoliko tvornica s poznatim lokacijama. Iz mikro perspektive, ovaj problem se pojavljuje kada moramo dodati novi stroj u postojeću mrežu strojeva proizvodnog pogona. S obzirom na to da je poznat volumen i smjer kretanja proizvodnih dijelova u proizvodnom pogonu, interakcija između novog i postojećih strojeva se može lako izračunati.

Razmatra se zapis:

c_i troškovi transporta između postojećeg skladišta i te novog skladišta, po jedinici

f_i tok prometa između postojećeg skladišta i te novog skladišta

x_i, y_i koordinate postojećeg skladišta i

Medijan metoda je onda:

$$\text{minimizirati } TC = \sum_{i=1}^m c_i f_i \left[|x_i - \bar{x}| + |y_i - \bar{y}| \right] \quad (2)$$

gdje TC predstavlja ukupne troškove distribucije, a \bar{x}, \bar{y} optimalne koordinate novog skladišta.

S obzirom na to da je umnožak $c_i f_i$ poznat za svako skladište, može se označiti kao težina w_i koji odgovara skladištu i . U budućem označavanju koristi se zapis w_i umjesto $c_i f_i$. Ako ponovno napišemo gornju formulu, izgledat će ovako:

$$\text{minimizirati } TC = \sum_{i=1}^m w_i |x_i - \bar{x}| + \sum_{i=1}^m w_i |y_i - \bar{y}| \quad (3)$$

S obzirom na to da x i y pojmovi mogu biti odijeljeni, mogu se izračunati optimalne \bar{x} i \bar{y} koordinate neovisno [1].

Koraci medijan metode:

- Korak 1 Poredati postojeća skladišta prema rastućem redosljedu x koordinata
- Korak 2 Pronaći j -tu x koordinatu u redosljedu, napravljenom u koraku 1, kod koje je kumulativna težina jednaka ili prelazi polovicu ukupne težine po prvi put:

$$\sum_{i=1}^{j-1} w_i < \sum_{i=1}^m \frac{w_i}{2} \quad \text{te} \quad \sum_{i=1}^j w_i \geq \sum_{i=1}^m \frac{w_i}{2} \quad (4)$$

- Korak 3 Poredati postojeća skladišta prema rastućem redosljedu y koordinata
- Korak 4 Pronaći k -atu y koordinatu u redosljedu, napravljenom u koraku 3, kod koje je kumulativna težina jednaka ili prelazi polovicu ukupne težine po prvi put:

$$\sum_{i=1}^{k-1} w_i < \sum_{i=1}^m \frac{w_i}{2} \quad \text{te} \quad \sum_{i=1}^k w_i \geq \sum_{i=1}^m \frac{w_i}{2} \quad (5)$$

Optimalna lokacija novog skladišta je dobivena iz j -ite x koordinate i k -ate y koordinate, dobivene iz koraka 2 i 4 [1].

2.3.4. Gravitacijska metoda

Gravitacijska metoda (*gravity method*) spada u tehnike određivanja kontinuirane lokacije. U nekim problemima lokacije skladišta, funkcije udaljenosti nisu linearne već nelinearne. Ako je nelinearna funkcija kvadratna, određivanje optimalne lokacije skladišta je vrlo jednostavno. Gravitacijska metoda se koristi za problem određivanja lokacije jednog skladišta s kvadratnom euklidskom udaljenošću:

$$\text{minimizirati } TC = \sum_{i=1}^m c_i f_i \left[(x_i - \bar{x})^2 + (y_i - \bar{y})^2 \right] \quad (6)$$

gdje TC predstavlja ukupne troškove distribucije, a \bar{x}, \bar{y} optimalne koordinate novog skladišta.

S obzirom na to da je umnožak $c_i f_i$ poznat za svako skladište, može se označiti kao težina w_i koji odgovara skladištu i . U budućem označavanju koristi se zapis w_i umjesto $c_i f_i$. Ako ponovno napišemo gornju formulu, izgledat će ovako:

$$\text{minimizirati } TC = \sum_{i=1}^m w_i (x_i - \bar{x})^2 + \sum_{i=1}^m w_i (y_i - \bar{y})^2 \quad (7)$$

S obzirom na to da ova funkcija može biti konveksna, djelomično razlikovanje TC u odnosu na \bar{x} i \bar{y} , postavljanje dviju jednadžbi koje proizlaze, na nulu i rješavanje \bar{x}, \bar{y} , osigurava optimalnu lokaciju novog skladišta:

$$\frac{\partial TC}{\partial \bar{x}} = 2 \sum_{i=1}^m w_i \bar{x} - 2 \sum_{i=1}^m w_i x_i = 0 \quad (8)$$

$$\therefore \bar{x} = \frac{\sum_{i=1}^m w_i x_i}{\sum_{i=1}^m w_i} \quad (9)$$

$$\frac{\partial TC}{\partial \bar{y}} = 2 \sum_{i=1}^m w_i \bar{y} - 2 \sum_{i=1}^m w_i y_i = 0 \quad (10)$$

$$\therefore \bar{y} = \frac{\sum_{i=1}^m w_i y_i}{\sum_{i=1}^m w_i} \quad (11)$$

Iz navedenog je vidljivo da su optimalne lokacije \bar{x} i \bar{y} jednostavno težinski prosjeci x i y koordinata postojećeg skladišta. Ova metoda određivanja optimalne lokacije skladišta se još popularno naziva *center-of-gravity*, *gravity* ili *centroid method*.

Ako je optimalna lokacija određena gravitacijskom metodom neizvediva, mogu se nacrtati izohipse iz susjednih točki, kako bi se pronašla izvediva lokacija, u blizini optimalne. Izohipse neće izgledati kao linije, već kao krugovi kroz točku, koja ima optimalnu lokaciju za središte. Prema tome, ako je optimalna lokacija (\bar{x}, \bar{y}) određena gravitacijskom metodom neizvediva za novo skladište, mora se naći bilo koja izvediva lokacija (x, y) koja ima najkraću euklidsku udaljenost (\bar{x}, \bar{y}) i smjestiti novo skladište na lokaciji (x, y) [1].

2.4. Višekriterijalno odlučivanje u primjeni rješavanja problema lokacije skladišta

Za razliku od kvantitativnih modela i metoda, ako je cilj određivanja lokacije skladišta, pored smanjenja prijednog puta (troškova transporta) između skladišta i trgovina (proizvodnih pogona), definiran s još mnogo različitih kriterija (cijena zemljišta, prometna povezanost, dostupnost i kvalificiranost radnika, itd.), problem lokacije skladišta rješava se metodama višekriterijalnog odlučivanja.

Problem donošenja odluke o lokaciji skladišta obuhvaća identifikaciju, analizu, procjenu i odabir između raznih alternativa. Takva odluka spada među najkritičnije odluke dizajna distribucijske mreže. Izbor jedne lokacije skladišta među raznim alternativama predstavlja problem višekriterijalnog odlučivanja, koji uključuje kvalitativne i kvantitativne kriterije. Izbor lokacije skladišta je od velike važnosti za kompaniju zbog visoke cijene koštanja i teškoće promjene. Takva odluka zahtjeva dugoročno opredjeljenje i ima utjecaj na troškove poslovanja a samim time i dobit. Na primjer, loš izbor lokacije skladišta može rezultirati prekomjernim troškovima transporta, nedostatkom kvalificirane radne snage, gubitkom konkurentske prednosti ili nekim sličnim problemom koji bi bio štetan za poslovanje [3].

3. VIŠEKRITERIJALNO ODLUČIVANJE

3.1. Prikaz

Višekriterijalno odlučivanje je zapravo donošenje odluke u prisutnosti više, često suprotstavljenih, kriterija. Problemi višekriterijalnog odlučivanja su prisutni u svakodnevnom životu. Na primjer, kod kupovine auta ili kuće mogu se definirati različiti kriteriji kao što su: cijena, veličina, lokacija, sigurnost, komfor, itd. U poslovnom svijetu, problemi višekriterijalnog odlučivanja, puno su kompleksniji [10]. Problem kompleksnosti nije samo u tome što uključuju puno kriterija, obzirom da neki kriteriji mogu težiti jednoj alternativu, kako bi se dobilo optimalno rješenje, sve alternative moraju imati zajedničke kriterije koji će dovesti do informirane i bolje odluke. Višekriterijalno odlučivanje se odnosi na strukturiranje, planiranje i rješavanje problema koji uključuje više kriterija [9].

Danas je višekriterijalno odlučivanje postalo jedno od najznačajnijih i najbrže rastućih polja operacijskih istraživanja. Razvoj modernog višekriterijalnog odlučivanja je započeo prije otprilike 50 godina, a usko je povezan s unaprjeđenjem informatičke tehnologije [13]. S jedne strane, brzi razvoj informatičke tehnologije je omogućio provođenje sustavne analize kompleksnih višekriterijalnih problema. S druge strane, masovno korištenje računala i informacijskih tehnologija je generiralo veliku količinu informacija, što je rezultiralo sve važnijim i korisnijim korištenjem višekriterijalnog odlučivanja u poslovnom svijetu [10].

Glavni cilj metodi višekriterijalnog odlučivanja je poduprijeti donositelje odluka kada postoji veliki izbor alternativa za problem koji rješava. Tipično, neophodno je korištenje osobne želje donositelja odluke, pri razlikovanju među rješenjima problema u kojem nema optimalnog rješenja. Rješenje problema se može tumačiti na različite načine. Može predstavljati odabir najboljeg od raznih ponuđenih alternativa, gdje se najbolja može tumačiti kao najpoželjnija alternativa donositelja odluke. Može pak odabrati mali skup dobrih alternativa ili grupirati alternative u različite skupove preferencija. Ovakva tumačenja se koriste kako bi se našle sve efikasne ili ne dominirajuće alternative [9].

Problem postaje kompleksniji kada se pojavljuje više kriterija. Jedinstveno optimalno rješenje problema višekriterijalnog odlučivanja može se dobiti bez ugradnje željenih informacija. Optimalno rješenje često može biti skriveno u skupu ne dominirajućih (non-dominated) rješenja. Takva ne dominirajuća rješenja imaju svojstvo da se bez žrtvovanja barem jednog kriterija ne može prijeći s ne dominirajućeg, na optimalno rješenje. Dakle,

donositelj odluke može lako odabrati rješenje iz skupa ne dominirajućih rješenja. U stvari, donositelj odluke ne može odabrati rješenje koje će biti gore u pogledu bilo kojeg kriterija, već može odabrati rješenje koje će biti bolje u pogledu svih kriterija. Međutim, skup ne dominirajućih rješenja (alternativa) je prevelik za završni izbor alternative donositelja odluke [9].

Višekriterijalno odlučivanje se kao i kvantitativni modeli, ovisno o problemu, može podijeliti na dva tipa: jedan koji ima ograničen broj rješenja (alternativa) i drugi koji ima neograničen broj rješenja (alternativa). Na primjer, kod problema povezanih s procjenom i odabirom, broj alternativa je ograničen. Kod problema povezanih s dizajnom, kriteriji mogu poprimiti bilo koju vrijednost u određenom rasponu, a samim time broj alternativa može bit neograničen [10]

Višekriterijalno odlučivanje se koristi kao snažna tehnika u donošenju odluke, a pronalazi svoju primjenu u: vrednovanju rada zaposlenika, procjeni zdravstvene zaštite u postupanju s otpadom, određivanju bankarske učinkovitosti, internet bankarstvu, određivanju najboljih profesora, odabiru dobavljača, upravljanjem lancem opskrbe, odabiru lokacije skladišta, itd. U nekim primjenama, pojavljuje se određena nesigurnost u odlučivanju, pa se koristi tzv. *fuzzy* višekriterijalno odlučivanje [9]. Ta nesigurnost može biti uzrokovana na dva načina. Prvi razlog je kada donositelj odluke nije 100% siguran pri donošenju neke subjektivne procjene, a naziva se nesigurnost subjektivne prosudbe. Drugi je razlog kada informacije o nekim kriterijima nisu potpune ili nisu dostupne uopće, a naziva se nesigurnost zbog nedostatka podataka ili nepotpunih informacija [10]. U principu, za rješavanje takvih problema koriste se izvedenice običnih metoda višekriterijalnog odlučivanja koje su namijenjene problemima definiranim s određenom nesigurnosti.

Pregledom literature [2, 3, 5, 6, 7, 8, 9, 10, 11, 12] pronađene su brojne metode višekriterijalnog odlučivanja:

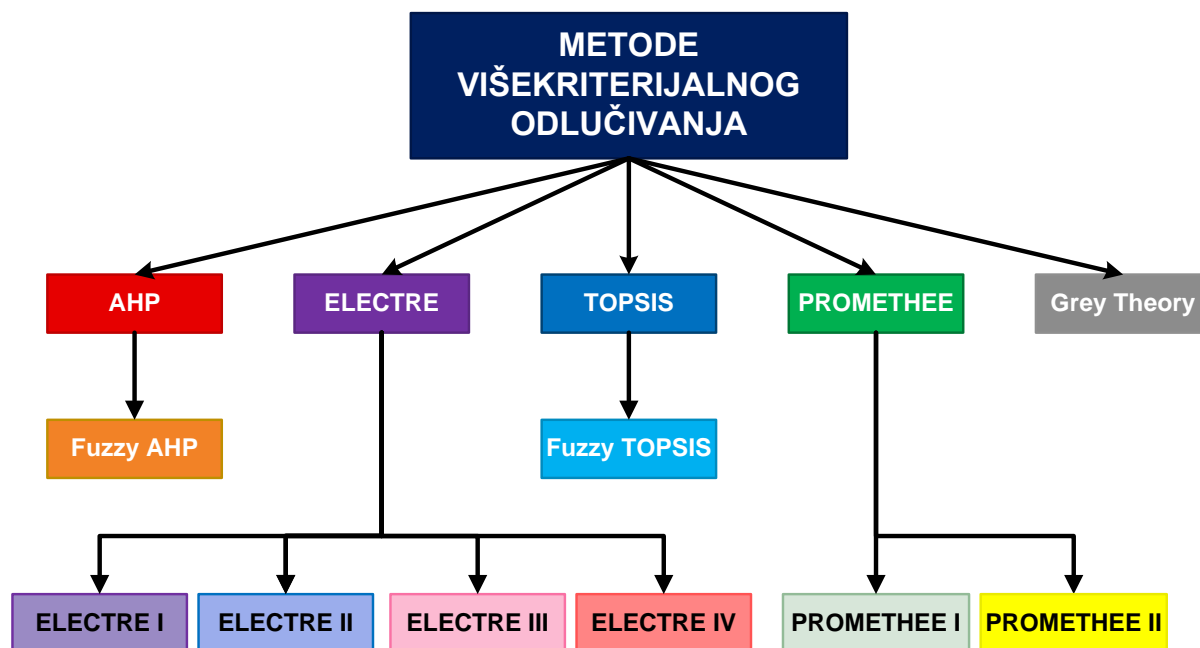
- *AIRM - Aggregated Indices Randomization Method,*
- *AHP - Analytic Hierarchy Process,*
- *ANP - Analytic Network Process,*
- *Chouquet integral,*
- *CBR - Case Based Reasoning,*
- *COPRAS-G - COmplex PROportional ASsessment of alternatives with Grey relations,*
- *DEA - Data Envelopment Analysis,*

- ELECTRE - *ELimination Et Choix Traduisant la REalité*,
- ER - *Evidential Reasoning Approach*,
- GP - *Goal Programming*,
- GRA - *Grey Relational Analysis*,
- *Grey Theory*,
- MAUT - *Multi-Attribute Utility Theory*,
- MAVT - *Multi-Attribute Value Theory*,
- MOORA - *Multi Objective Optimization on the basis of Ratio Analysis*,
- OCRA - *Operational Competitiveness Rating Analysis*,
- PROMETHEE - *Preference Ranking Organization METHod for Enrichment of Evaluations*,
- REGIME - *Final Ranking Method*,
- SAW - *Simple Additive Weighting*,
- SMART - *Simple Multi-Attribute Rating Technique*,
- TOPSIS - *Technique for Order of Preference by Similarity to Ideal Solution*,
- VIKOR - *VIšekriterijumsko KOmpromisno Rangiranje*,
- WPM - *Weighted Product Model*,
- WSM - *Weighted Sum Model*.

Osim navedenih, postoje još mnoge druge metode višekriterijalnog odlučivanja. Također postoje i tzv. *fuzzy* izvedenice metoda, kao što su: *fuzzy* AHP, *fuzzy* TOPSIS, itd. U točki 3.2 ovog diplomskog rada, daje se pregled često korištenih višekriterijalnih metoda koje su pregledom literature [3, 5, 6, 7, 8, 9] našle svoju primjenu u odabiru lokacije skladišta ili distribucijskog centra.

3.2. Pregled metoda

Slika 5. prikazuje hijerarhijski pregled metoda višekriterijalnog odlučivanja koje su pregledom literature upotrijebljene pri odabiru lokacije skladišta ili distribucijskog centra.



Slika 5. Hijerarhijski pregled metoda višekriterijalnog odlučivanja [9]

3.2.1. AHP

AHP metodu je razvio Thomas L. Saaty 1970-ih godina, a skraćeni naziv dolazi od engleskog naziva *analytic hierarchy process*. U prijevodu AHP znači: analitički hijerarhijski proces. Osnovna ideja AHP metode je obuhvatiti znanje stručnjaka o fenomenu studije. Donositelji odluke često smatraju da je bolje davati svoje procjene nego imati fiksni vrijednosni sustav. AHP obuhvaća mišljenje stručnjaka i višekriterijalna vrednovanja. Analitički hijerarhijski proces rastavlja kompleksni višekriterijalni problem na sustavnu hijerarhijsku proceduru. Zadnji korak u AHP metodi, bavi se strukturom matrice $m * n$ (gdje je m broj alternativa, a n broj kriterija). Matrica je konstruirana u smislu svakog kriterija, korištenjem relativne važnosti alternativa. Analitički hijerarhijski proces se zasniva na teoriji prioriteta, a koristi se u rješavanju kompleksnih problema koji uključuju razmatranje više kriterija istovremeno [9]. Roh i sur [7], primijenili su AHP metodu pri određivanju relativnih važnosti (težina) kriterija i potkriterija, u izboru lokacije skladišta humanitarne pomoći. *Fuzzy AHP* se koristi kada korisnikova preferencija nije izričito definirana zbog neizrazite naravi. U *fuzzy AHP* metodi težine su izražene neophodnim ili mogućim mjerama [9]. Ashrafzadeh i sur. [9] primijenili su *fuzzy AHP* metodu pri odabiru lokacije skladišta Entekhab kompanije u Iranu.

3.2.2. ELECTRE

Prvi put je predstavio Bernard Roy 1965. godine, a skraćeni naziv dolazi od francuskog naziva *elimination et choix traduisant la réalité*. U prijevodu bi ELECTRE značilo: eliminacija i izbor izražavanja stvarnosti. ELECTRE metoda je jedna od višekriterijalnih metoda, a dozvoljava donositelju odluke izbor najbolje odluke, s maksimalnom prednosti i minimalnim sukobima u funkciji različitih kriterija. Kad je predstavljena, ELECTRE metoda se koristila za izbor najbolje radnje iz danog skupa radnji, ali je ubrzo našla primjenu na 3 glavna problema: odabir, rangiranje, sortiranje. Predstavljena metoda je evoluirala u ELECTRE I, a daljnjom evolucijom, kasnije su predstavljene: ELECTRE II, ELECTRE III, ELECTRE IV, ELECTRE IS i ELECTRE TRI. Sve metode se zasnivaju na temeljnim konceptima ali i razlikuju u operativnom smislu te vrsti problema odlučivanja. ELECTRE I je namijenjena za probleme odabira, ELECTRE II, III i IV za probleme rangiranja, a ELECTRE TRI za probleme dodjeljivanja. ELECTRE stvara mogućnost za modeliranje procesa odlučivanja korištenjem pokazatelja koordinacije. Ti pokazatelji su matrice slaganja i neslaganja. Donositelj odluke koristi pokazatelje slaganja i neslaganja kako bi analizirao odnose između različitih alternativa i odabrao najbolju [9]. Ozcan i sur. [5], pored ostalih, primijenili su i ELECTRE metodu u odabiru lokacije skladišta.

3.2.3. TOPSIS

Hwang i Yoon 1981. godine razvili su TOPSIS metodu, a kasnije je usavršena 1987. godine od strane Yoona te Hwanga, Lai i Liu 1993. godine. Skraćeni naziv dolazi od engleskog naziva *technique for order of preference by similarity to ideal solution*. U prijevodu bi TOPSIS značilo: tehnike redoslijeda preferencija po sličnosti idealnom rješenju. Temelji se na konceptu koji izabire alternativu koja bi trebala imati najmanju geometrijsku udaljenost od pozitivnog idealnog rješenja i najveću geometrijsku udaljenost od negativnog idealnog rješenja. To je kompenzacijska metoda koja uspoređuje alternative određivanjem relativnih važnosti (težina) kriterija, normalizacijom rezultata za svaki kriterij te izračunom geometrijske udaljenosti između idealne alternative i svake pojedine alternative. Pretpostavka TOPSIS metode je da se kriteriji jednoliko povećavaju ili smanjuju, što dovodi do jednostavnog definiranja pozitivnog i negativnog idealnog rješenja. Za određivanje relativne udaljenosti alternativa od idealnog rješenja koristi se euklidska udaljenost. Niz usporedbi ovih relativnih udaljenosti će osigurati željeni redoslijed alternativa. S obzirom na to da su parametri kriterija često neprikladnih dimenzija, potrebna je normalizacija. TOPSIS metoda

dozvoljava kompenzaciju između kriterija. Ova metoda se koristi za rangiranje i dobivanje najboljih performansi u višekriterijalnom odlučivanju [9]. Ozcan i sur. [5], pored ostalih, primijenili su i TOPSIS metodu u odabiru lokacije skladišta. *Fuzzy* TOPSIS metoda se koristi za procjenu kriterija u svakoj regiji i konačnom rangiranju svih kriterija s obzirom na regiju [9]. Awasthi i sur. [8] primijenili su *fuzzy* TOPSIS metodu za odabir lokacije distribucijskog centra.

3.2.4. PROMETHEE

PROMETHEE metodu je razvio Jean-Pierre Brans 1982. godine, a skraćeni naziv dolazi od engleskog naziva *preference ranking organization method for enrichment of evaluations*. Kasnije su je razvili i implementirali Jean-Pierre Brans te Bertrand Mareschal uključujući i dodatke kao što je GAIA (*geometrical analysis for interactive aid*). U prijevodu bi PROMETHEE značilo: metoda organizacije rangiranja preferencija za obogaćivanje procjene. Deskriptivni pristup nazvan GAIA, omogućuje donositelju odluke, vizualizaciju glavnih obilježja problema odlučivanja. Preskriptivni pristup nazvan PROMETHEE, osigurava donositelju odluke, kompletno i djelomično rangiranje radnji. PROMETHEE metodom se mogu koristiti pojedinci u jednostavnom odlučivanju ali je najkorisnija kada skupina ljudi rješava složene probleme, pogotovo one sa više kriterija. Ova metoda uključuje mnogo prosudbi i percepcije ljudi čije odluke imaju dugoročan utjecaj. Ima jedinstvenu prednost kada je teško usporediti ili kvantificirati važne elemente odluke ili kada je suradnja među odjelima ili članovima tima ograničena zbog njihovih različitih specijalizacija ili stajališta. Osnovna ideja PROMETHEE metode je razmotriti preferencije donositelja odluke. Donositelj odluke treba odrediti jednu od šest generaliziranih preferencijalnih funkcija i odgovarajuće granične vrijednosti za svaki kriterij na najnižoj razini hijerarhije (preferencijalne informacije unutar kriterija). Druga vrsta preferencija su preferencijalne informacije između kriterija koji odražavaju relativnu važnost jednog cilja u odnosu na ostale ciljeve, obzirom na težinske faktore. Za procjenu objektivnih težina mogu se koristiti različite metode. PROMETHEE I i II dovode do dva različita načina rangiranja [6]. PROMETHEE I se temelji na pozitivnim i negativnim tokovima, uključuje preferencije, indiferentnost i neusporedivost, a dovodi do djelomičnog rangiranja. PROMETHEE II se temelji na višekriterijalnom toku, uključuje preferencije i indiferentnost, a dovodi do kompletnog rangiranja. Degener i sur. [6] primijenili su PROMETHEE metodu pri odabiru lokacije skladišta u područjima prirodnih katastrofa, na sjeveroistoku Bangladeša.

3.2.5. *Grey theory*

To je metoda koja se koristi za proučavanje nesigurnosti, a superiorna je u matematičkim analizama sustava s neizvjesnim informacijama. Izvorno razvijena od strane prof. Denga 1982. godine, postala je vrlo učinkovita metoda u rješavanju problema nesigurnosti, uzrokovanim diskretnim podacima i nepotpunim informacijama [14]. U prijevodu bi *grey theory* značilo: siva teorija. Koristi se u rješavanju problema odlučivanja povezanih sa sivim sustavima, definiranih s malo informacija i podataka, poznatih na specifičnoj ljestvici i nepoznatih na specifičnoj ljestvici [5]. *Grey theory* se bavi visokom matematičkom analizom sustava koji su djelomično poznati i djelomično nepoznati, a definirani su s nedovoljno podataka i nedovoljno znanja. Kada proces odlučivanja nije jasan, *grey theory* ispituje interakcijsku analizu, postoji veliki broj ulaznih podataka koji se razlikuju i nepotpuni su. Zadnjih godina, u rješavanju mnogih problema odlučivanja, uspješno se koristi njena metodologija [9]. Pored višekriterijalnog odlučivanja, koristi se i u računalnoj grafici, prognoziranju te kontroli sustava. [14]. Ozcan i sur. [5], pored ostalih, primijenili su i *grey theory* u odabiru lokacije skladišta.

4. AHP METODA

4.1. Definicija

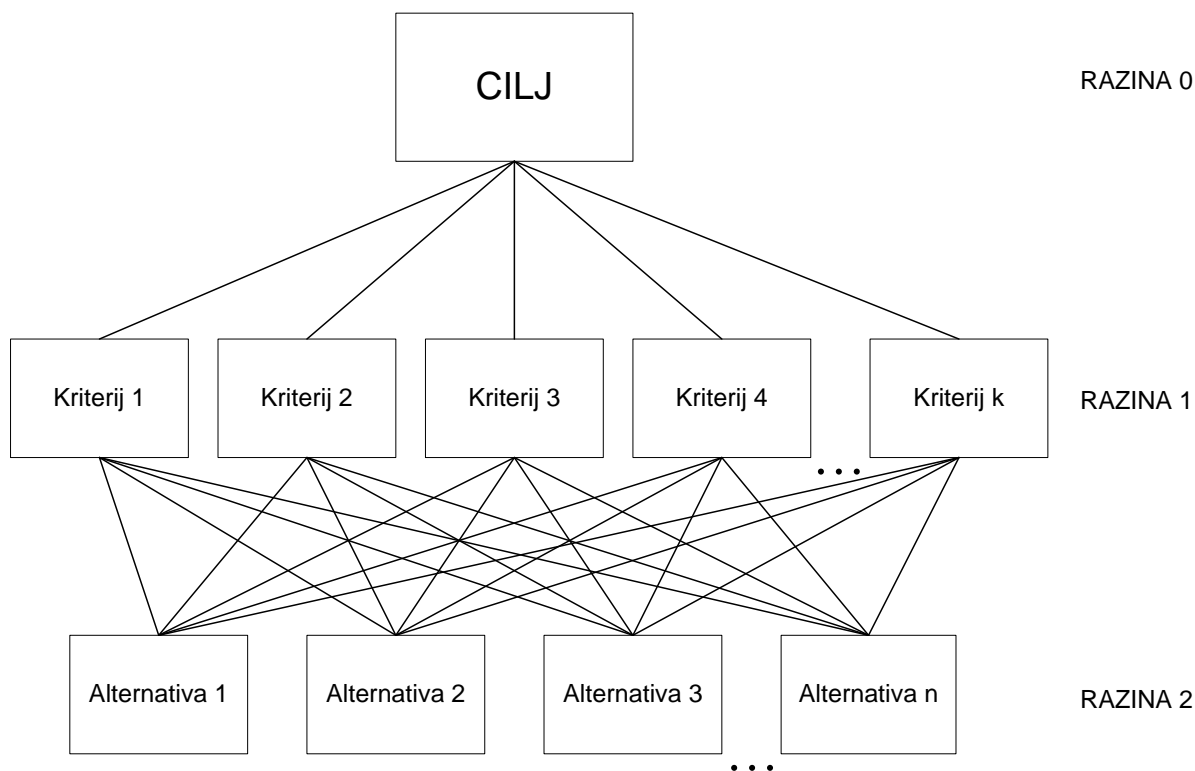
AHP (*analytic hierarchy process*), odnosno analitički hijerarhijski proces je strukturirana tehnika za organizaciju i analizu složenih odluka, a bazira se na matematici i psihologiji. Ta metoda ima posebnu primjenu u grupnim odlučivanjima, a koristi se diljem svijeta u širokom spektru odlučivanja, kao što su: vlada, biznis, industrija, zdravstvo i obrazovanje.

AHP spada u najpoznatije i posljednjih godina najkorištenije metode za višekriterijalno odlučivanje. Metodu svojstvenog vektora osmislio je Thomas L. Saaty 1971. godine, a nakon nekoliko godina istraživanja i revizije objavio 1980. godine [15]. Njezina popularnost proizlazi iz činjenice da je vrlo bliska načinu na koji pojedinac rješava složene probleme, rastavljajući ih na jednostavnije komponente: cilj, kriterije i alternative. Te se komponente povezuju u model u kojemu je na najvišoj razini cilj, na prvoj nižoj razini nalaze se kriteriji, na drugoj nižoj njihovi potkriteriji, a na najnižoj razini su alternative (mogućnosti) [16].

4.2. Struktura i način funkcioniranja

AHP metoda se sastoji od četiri osnovna koraka:

- Korak 1 Napraviti hijerarhijsku strukturu problema odlučivanja s ciljem na vrhu, kriterijima i potkriterijima na nižim razinama, te alternativama na dnu modela [Slika 6].
- Korak 2 Na svakoj razini hijerarhijske strukture u parovima međusobno usporediti elemente te strukture, pri čemu preferencije donositelja odluke treba izraziti uz pomoć odgovarajuće Saatyjeve skale [Slika 7].
- Korak 3 Procjenom relativnih važnosti elemenata za odgovarajuću razinu hijerarhijske strukture problema pomoću odgovarajućeg matematičkog modela izračunati lokalne prioritete (težine) kriterija, potkriterija i alternativa.
- Korak 4 Sintetiziranjem lokalnih prioriteta u ukupne prioritete alternativa odrediti konačno rješenje [16].



Slika 6. Hijerarhijska struktura AHP modela s kriterijima i alternativama

Ideja AHP metode je prvo postaviti cilj, zatim odrediti kriterije koji mogu zadovoljiti taj cilj, a bitno utječu na konačnu odluku donositelja odluke. Kriteriji se mogu svrstati u jednu ili više razina (prva, druga, treća itd.) čime se postiže hijerarhija kriterija. Kriteriji prve razine najviše utječu na odluku, odnosno najvažniji su, dok kriteriji druge, treće itd. razine imaju manji utjecaj na konačnu odluku donositelja odluke. Kriteriji u hijerarhiji mogu se odnositi na bilo kakav aspekt problema odlučivanja, materijalan ili nematerijalan, pažljivo mjeren ili grubo procijenjen, dobro ili loše shvaćen, u principu sve što može pomoći pri donošenju odluke [17].

Nakon što je hijerarhija napravljena, donositelj odluke sustavno ocjenjuje kriterije i potkriterije uspoređujući ih međusobno u parovima, s obzirom na njihov utjecaj na element iznad njih u hijerarhiji. Prioritet kojeg jedan kriterij ima u odnosu na drugi izražava se opisnim vrijednostima kao što su: umjereno, jako, vrlo jako, apsolutno. U izradi usporedbe, donositelj odluke može koristiti konkretne podatke, međutim najčešće su to osobne prosudbe o elementima. Bit AHP metode je da ljudski sud, a ne samo temeljne informacije, utječu na procjenu prioriteta. Usporedba se radi prema Saatyjevoj skali [Slika 7].

Ocjena prioriteta	Opisna ocjena prioriteta	
1	Jednaki prioritet	Equal
2	Jednaki do umjereni prioritet	Intermediate favors
3	Umjereni prioritet	Slightly favors
4	Umjereni do jaki prioritet	Intermediate favors
5	Jaki prioritet	Strongly favors
6	Jaki do vrlo jaki prioritet	Intermediate favors
7	Vrlo jaki prioritet	Very strong favors
8	Vrlo jaki do apsolutni prioritet	Intermediate favors
9	Apsolutni prioritet	Extreme favors

Slika 7. Saatyjeva skala prioriteta [18]

AHP pretvara procjene iz Saatyjeve skale u brojčane vrijednosti koje mogu biti obrađene i uspoređene s obzirom na cijeli raspon problema. Navedene težine prioriteta se računaju za svaki kriterij u hijerarhiji, dozvoljavajući usporedbu različitih i često nemjerljivih elemenata na racionalan i dosljedan način. Ova mogućnost razlikuje AHP od ostalih tehnika odlučivanja [17].


U završnoj fazi procesa težine prioriteta se računaju za svaku alternativu. Ti brojevi predstavljaju alternative odnosno njihovu relativnu sposobnost da se postigne cilj, tako da omogućuju izravno promatranje različitih načina djelovanja.

Umjesto propisivanja ispravne odluke, AHP metoda pomaže donositeljima odluke da nađu odgovor koji najbolje odgovara cilju i njihovom razumijevanju problema [17].

4.3. Konzistentnost

AHP metoda omogućuje provjeru konzistentnosti procjena donositelja odluke nakon uspoređivanja elemenata hijerarhije. Zbog svojstava matrice A vrijedi $\lambda_{\max} \geq n$. Gdje je λ_{\max} maksimalna vrijednost matrice A , a n broj redova matrice. Razlika $\lambda_{\max} - n$ se koristi u mjerenju konzistentnosti procjena. Što je razlika manja, prosudba je konzistentnija [17].

Problem konzistentnosti odnosno dosljednosti provjerava se na idući način:



Slika 8. Primjer konzistentnosti [18]

Na primjer, Ante voli više banane nego jabuke, $B > A$, ali također više voli jabuke nego trešnje, $A > C$. Obzirom da je Ante preferirao više banane od jabuka, $B > A$, a jabuke od trešanja, $A > C$, logički se zaključuje da Ante više voli banane od trešanja, $B > C$. Obzirom da je Antin odgovor u ovom slučaju bio da više preferira banane od trešanja, $B > C$, njegova je prosudba konzistentna.

Da je Ante kojim slučajem odgovorio kako voli više trešnje od banana $C > B$, onda njegova odluka nebi bila konzistentna. Problemi nastaju upravo zbog toga što naše procjene obično nisu konzistentne.

AHP metoda omogućuje provjeru konzistentnosti procjena prilikom uspoređivanja u parovima. Pomoću indeksa konzistentnosti $CI = (\lambda_{\max} - n) / (n - 1)$ izračunava se omjer konzistentnosti $CR = CI / RI$, gdje je RI slučajni indeks konzistentnosti (indeks konzistentnosti za matrice reda n slučajno generiranih usporedbi u parovima). Za određivanje RI pomoću n , koristi se tablica 1. s izračunatim vrijednostima.

Tablica 1. Vrijednosti RI slučajnih indeksa [15]

n	1	2	3	4	5	6	7	8	9	10
RI	0	0	0.58	0.9	1.12	1.24	1.32	1.41	1.45	1.49

Kada za matricu A vrijedi $CR \leq 0,10$, procjene relativnih važnosti (težina) kriterija (alternativa) smatraju se prihvatljivima. U ostalim slučajevima potrebno je istražiti razloge zbog kojih je došlo do neprihvatljivo visoke nekonzistentnosti procjena [16].

4.4. AHP na primjeru odabira lokacije skladišta

Na primjer, neka kompanija s nesigurnosti potražnje i visokom raznolikosti proizvoda treba skladište odakle bi najbrže, najjednostavnije i najjeftinije bilo dostavljati robu trgovinama. Poznavajući problem odabira lokacije skladišta zaključuje se kako isti može predstavljati efikasnu strategiju dugoročne investicijske odluke i profitabilnosti ulaganja ili totalni promašaj i trošak za kompaniju. Izbor je smanjen na četiri skladišta, međutim jako teško se odlučiti za najbolje rješenje s obzirom na vrlo slične karakteristike istih.

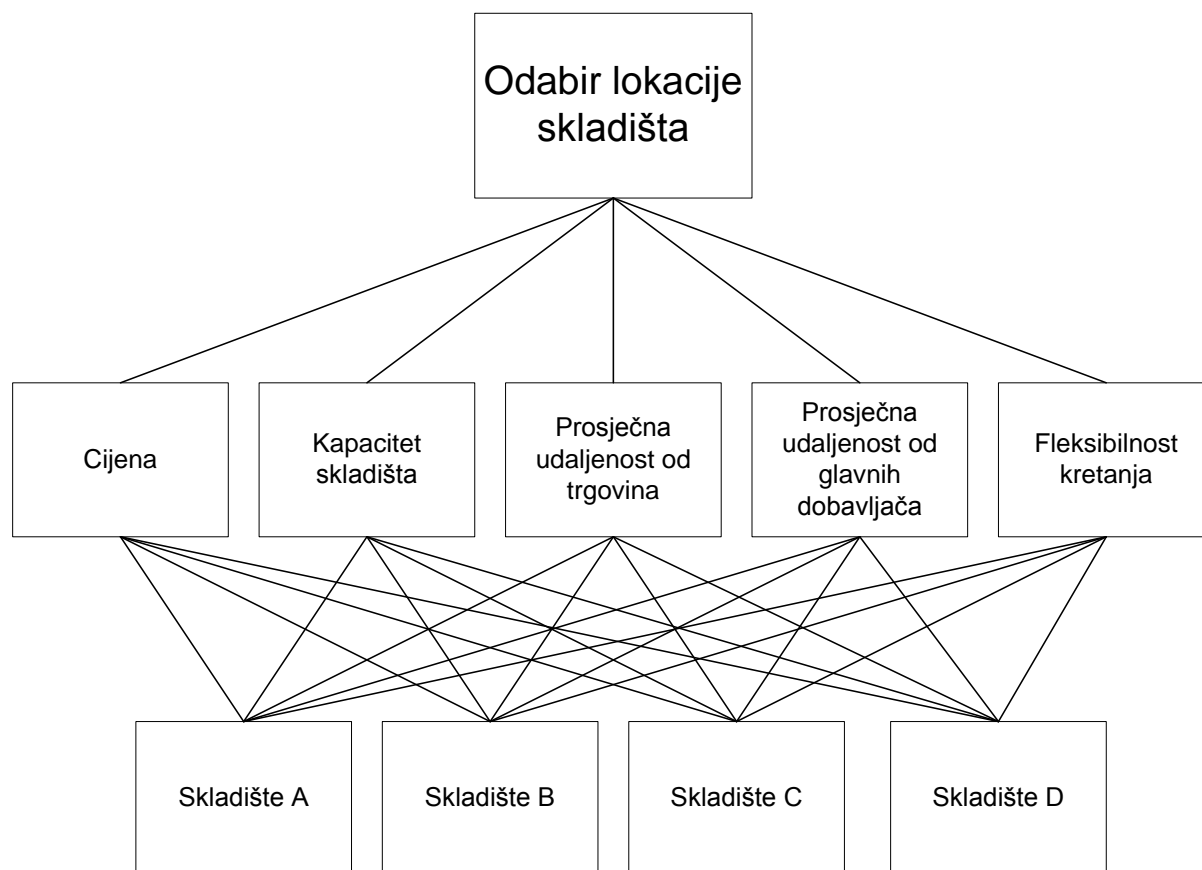
Kad bi se radilo o jednostavnom problemu, menadžeri kompanije bi se lako usuglasili i odabrali najbolje rješenje po kompaniju, međutim u ovakvoj ozbiljnoj poslovnoj odluci najčešće se služe različitim matematičkim metodama poput AHP metode. Problem koji će se predstaviti rješavanjem pomoću AHP metode dan je u tablici 2.

Tablica 2. Primjer odabira lokacije skladišta [5]

ALTERNATIVE	CIJENA (€/m ²)	KAPACITET SKLADIŠTA (jedinice)	PROSJEČNA UDALJENOST OD TRGOVINA (km)	PROSJEČNA UDALJENOST OD GLAVNIH DOBAVLJAČA (km)	FLEKSIBILNOST KRETANJA (0-4)
SKLADIŠTE A	7	100 000	20	14	3
SKLADIŠTE B	10	120 000	8	10	1
SKLADIŠTE C	8	150 000	12	12	2
SKLADIŠTE D	6	180 000	16	13	4

4.4.1. Strukturiranje problema [18]

U nastavku se prikazuje hijerarhijska struktura problema odlučivanja s ciljem na vrhu, kriterijima na nižim razinama i alternativama na dnu modela [Slika 9].



Slika 9. Hijerarhijska struktura problema [5]

4.4.2. Određivanje najznačajnijeg kriterija [18]

4.4.2.1. Definicija matrice odlučivanja

Prvo se provodi usporedba kriterija u parovima prema Saatyjevoj skali, vidljivo na slici 9., a zatim se definira matrica odlučivanja. Kod definicije matrice odlučivanja postoje dva pravila. Prvo pravilo kaže: "Ako se iznos usporedbe nalazi na lijevoj strani Saatyjeve skale, u matricu se upisuje isti taj iznos". Drugo pravilo kaže: "Ako se iznos usporedbe nalazi na desnoj strani Saatyjeve skale u matricu se upisuje recipročna vrijednost iznosa". Koristeći prethodna dva pravila dobiva se matrica odlučivanja vidljiva u tablici 3.



Slika 10. Prikaz usporedbi na Saatyjevoj skali

Tablica 3. Matrica odlučivanja

	CIJENA	KAPACITET SKLADIŠTA	PROSJEČNA UDALJENOST OD TRGOVINA	PROSJEČNA UDALJENOST OD GLAVNIH DOBAVLJAČA	FLEKSIBILNOST KRETANJA
CIJENA	1	1	2	2	4
KAPACITET SKLADIŠTA	1	1	3	3	4
PROSJEČNA UDALJENOST OD TRGOVINA	1/2	1/3	1	1	4
PROSJEČNA UDALJENOST OD GLAVNIH DOBAVLJAČA	1/2	1/3	1	1	4
FLEKSIBILNOST KRETANJA	1/4	1/4	1/4	1/4	1

4.4.2.2. Množenje matrice odlučivanja

Množenjem prethodne matrice odlučivanja dobiva se nova matrica:

$$\begin{bmatrix} 1 & 1 & 2 & 2 & 4 \\ 1 & 1 & 3 & 3 & 4 \\ 0,5 & 0,3333 & 1 & 1 & 4 \\ 0,5 & 0,3333 & 1 & 1 & 4 \\ 0,25 & 0,25 & 0,25 & 0,25 & 1 \end{bmatrix} *$$

$$\begin{bmatrix} 1 & 1 & 2 & 2 & 4 \\ 1 & 1 & 3 & 3 & 4 \\ 0,5 & 0,3333 & 1 & 1 & 4 \\ 0,5 & 0,3333 & 1 & 1 & 4 \\ 0,25 & 0,25 & 0,25 & 0,25 & 1 \end{bmatrix} =$$

$$\begin{bmatrix} 5 & 4,3332 & 10 & 10 & 28 \\ 6 & 5 & 12 & 12 & 36 \\ 2,8333 & 2,5 & 5 & 5 & 15,3332 \\ 2,8333 & 2,5 & 5 & 5 & 15,3332 \\ 1 & 0,9167 & 2 & 2 & 5 \end{bmatrix}$$

Tablica 4. Matrica odlučivanja nakon prvog množenja

	CIJENA	KAPACITET SKLADIŠTA	PROSJEČNA UDALJENOST OD TRGOVINA	PROSJEČNA UDALJENOST OD GLAVNIH DOBAVLJAČA	FLEKSIBILNOST KRETANJA
CIJENA	5	4,3332	10	10	28
KAPACITET SKLADIŠTA	6	5	12	12	36
PROSJEČNA UDALJENOST OD TRGOVINA	2,8333	2,5	5	5	15,3332
PROSJEČNA UDALJENOST OD GLAVNIH DOBAVLJAČA	2,8333	2,5	5	5	15,3332
FLEKSIBILNOST KRETANJA	1	0,9167	2	2	5

4.4.2.3. Određivanje 1. vektora prioriteta (eigenvector)

Sumiranje redova matrice:

$$\begin{array}{ccccc|c}
 5 & 4,3332 & 10 & 10 & 28 & 57,3332 \\
 6 & 5 & 12 & 12 & 36 & 71 \\
 2,8333 & 2,5 & 5 & 5 & 15,3332 & = 30,6665 \\
 2,8333 & 2,5 & 5 & 5 & 15,3332 & 30,6665 \\
 1 & 0,9167 & 2 & 2 & 5 & 10,9167 \\
 \hline
 & & & & & 200,5829
 \end{array}$$

Normalizacija sume redova:

$$\begin{array}{c|c}
 \begin{bmatrix} 57,3332 / 200,5829 \\ 71 / 200,5829 \\ 30,6665 / 200,5829 \\ 30,6665 / 200,5829 \\ 10,9167 / 200,5829 \end{bmatrix} & \rightarrow \begin{bmatrix} 0,2858 \\ 0,3540 \\ 0,1529 \\ 0,1529 \\ 0,0544 \end{bmatrix}
 \end{array}$$

1. vektor prioriteta

4.4.2.4. Množenje matrice odlučivanja

Množenjem prethodne matrice odlučivanja dobiva se nova matrica:

$$\begin{bmatrix} 5 & 4,3332 & 10 & 10 & 28 \\ 6 & 5 & 12 & 12 & 36 \\ 2,8333 & 2,5 & 5 & 5 & 15,3332 \\ 2,8333 & 2,5 & 5 & 5 & 15,3332 \\ 1 & 0,9167 & 2 & 2 & 5 \end{bmatrix} * \begin{bmatrix} 5 & 4,3332 & 10 & 10 & 28 \\ 6 & 5 & 12 & 12 & 36 \\ 2,8333 & 2,5 & 5 & 5 & 15,3332 \\ 2,8333 & 2,5 & 5 & 5 & 15,3332 \\ 1 & 0,9167 & 2 & 2 & 5 \end{bmatrix} = \begin{bmatrix} 135,6652 & 118,9996 & 257,9984 & 257,9984 & 742,6592 \\ 163,9992 & 144,0004 & 312 & 312 & 895,9968 \\ 72,8327 & 63,8332 & 138,9994 & 138,9994 & 399,3304 \\ 272,8327 & 63,8332 & 138,9994 & 138,9994 & 399,3304 \\ 26,8334 & 24,8334 & 51,0004 & 51,0004 & 147,334 \end{bmatrix}$$

Tablica 5. Matrica odlučivanja nakon drugog množenja

	CIJENA	KAPACITET SKLADIŠTA	PROSJEČNA UDALJENOST OD TRGOVINA	PROSJEČNA UDALJENOST OD GLAVNIH DOBAVLJAČA	FLEKSIBILNOST KRETANJA
CIJENA	135,6652	118,9996	257,9984	257,9984	742,6592
KAPACITET SKLADIŠTA	163,9992	144,0004	312	312	895,9968
PROSJEČNA UDALJENOST OD TRGOVINA	72,8327	63,8332	138,9994	138,9994	399,3304
PROSJEČNA UDALJENOST OD GLAVNIH DOBAVLJAČA	72,8327	63,8332	138,9994	138,9994	399,3304
FLEKSIBILNOST KRETANJA	26,8334	24,8334	51,0004	51,0004	147,334

4.4.2.5. Određivanje 2. vektora prioriteta (eigenvector)

Sumiranje redova matrice:

$$\begin{array}{ccccc|c}
 135,6652 & 118,9996 & 257,9984 & 257,9984 & 742,6592 & 1513,3208 \\
 163,9992 & 144,0004 & 312 & 312 & 895,9968 & 1827,964 \\
 72,8327 & 63,8332 & 138,9994 & 138,9994 & 399,3304 & 813,9951 \\
 272,8327 & 63,8332 & 138,9994 & 138,9994 & 399,3304 & 813,9951 \\
 26,8334 & 23,5002 & 51,0004 & 51,0004 & 147,334 & 299,6684 \\
 \hline
 & & & & & 5268,9758
 \end{array}$$

Normalizacija sume redova:

$$\begin{array}{c}
 1513,3208 / 5268,9758 \\
 1827,9964 / 5268,9758 \\
 813,9951 / 5268,9758 \\
 813,9951 / 5268,9758 \\
 299,6684 / 5268,9758
 \end{array}
 \rightarrow
 \begin{array}{c}
 0,2872 \\
 0,3469 \\
 0,1545 \\
 0,1545 \\
 0,0569
 \end{array}$$

2. vektor prioriteta

Izračunavanje razlike vektora prioriteta:

$$\begin{array}{c}
 0,2858 \\
 0,3540 \\
 0,1529 \\
 0,1529 \\
 0,0544
 \end{array}
 -
 \begin{array}{c}
 0,2872 \\
 0,3469 \\
 0,1545 \\
 0,1545 \\
 0,0569
 \end{array}
 =
 \begin{array}{c}
 -0,0014 \\
 0,0071 \\
 -0,0016 \\
 -0,0016 \\
 -0,0025
 \end{array}$$

1. vektor 2. vektor vektor razlika

Zbog malih iznosa vektora razlika, nije potrebno daljnje izračunavanje vektora prioriteta kriterija.

4.4.2.6. Određivanje najznačajnijeg kriterija

	Cijena	Kapacitet	Trgovine	Dobavljači	Fleksibilnost	
Cijena	1	1	2	2	4	0,2872
Kapacitet	1	1	3	3	4	0,3469
Trgovine	0,5	0,3333	1	1	4	0,1545
Dobavljači	0,5	0,3333	1	1	4	0,1545
Fleksibilno	0,25	0,25	0,25	0,25	1	0,0569

Matrica odlučivanja 2. vektor prioriteta

S obzirom na izračunati vektor prioriteta, kao najznačajniji kriterij dobiva se kapacitet skladišta.

4.4.3. Određivanje najznačajnije alternative [18]

AHP metoda može kombinirati kvalitativne ali i kvantitativne podatke

4.4.3.1. Cijena (€/m²)

Skladište A	7	7 / 31	0,2258
Skladište B	10	10 / 31	0,3226
Skladište C	8	8 / 31	0,2581
Skladište D	6	6 / 31	0,1935
	31	1,0000	

S obzirom na to da AHP metoda uzima najveću težinu ujedno i za najznačajniju, kao najbolje skladište je dobiveno skladište B. Međutim, u gornjem primjeru je vidljivo kako je skladište B zapravo najskuplje skladište, dok je najjeftinije skladište D. Zbog svega navedenoga prilagođava se proračun kako bi najveća težina dala najbolju alternativu.

Skladište A	7	31 / 7	4,4286	4,4286 / 16,5703	0,2673
Skladište B	10	31 / 10	3,1	3,1 / 16,5703	0,1871
Skladište C	8	31 / 8	3,875	3,875 / 16,5703	0,2338
Skladište D	6	31 / 6	5,1667	5,1667 / 16,5703	0,3118
	31	16,5703			

4.4.3.2. Kapacitet skladišta (jedinice)

Skladište A	$\begin{bmatrix} 100.000 \end{bmatrix}$	\rightarrow	$\begin{bmatrix} 100.000 / 550.000 \end{bmatrix}$	$=$	$\begin{bmatrix} 0,1818 \end{bmatrix}$
Skladište B	$\begin{bmatrix} 120.000 \end{bmatrix}$		$\begin{bmatrix} 120.000 / 550.000 \end{bmatrix}$		$\begin{bmatrix} 0,2182 \end{bmatrix}$
Skladište C	$\begin{bmatrix} 150.000 \end{bmatrix}$		$\begin{bmatrix} 150.000 / 550.000 \end{bmatrix}$		$\begin{bmatrix} 0,2727 \end{bmatrix}$
Skladište D	$\begin{bmatrix} 180.000 \end{bmatrix}$		$\begin{bmatrix} 180.000 / 550.000 \end{bmatrix}$		$\begin{bmatrix} 0,3273 \end{bmatrix}$
	<u>550.000</u>				<u>1,0000</u>

4.4.3.3. Prosječna udaljenost od trgovina (km)

Skladište A	$\begin{bmatrix} 20 \end{bmatrix}$	\rightarrow	$\begin{bmatrix} 20 / 56 \end{bmatrix}$	$=$	$\begin{bmatrix} 0,3571 \end{bmatrix}$
Skladište B	$\begin{bmatrix} 8 \end{bmatrix}$		$\begin{bmatrix} 8 / 56 \end{bmatrix}$		$\begin{bmatrix} 0,1429 \end{bmatrix}$
Skladište C	$\begin{bmatrix} 12 \end{bmatrix}$		$\begin{bmatrix} 12 / 56 \end{bmatrix}$		$\begin{bmatrix} 0,2143 \end{bmatrix}$
Skladište D	$\begin{bmatrix} 16 \end{bmatrix}$		$\begin{bmatrix} 16 / 56 \end{bmatrix}$		$\begin{bmatrix} 0,2857 \end{bmatrix}$
	<u>56</u>				<u>1,0000</u>

S obzirom na to da AHP metoda uzima najveću težinu ujedno i za najznačajniju, kao najbolje skladište je dobiveno skladište A. Međutim, u gornjem primjeru je vidljivo kako je najbolja opcija skladište s najmanjom težinom, odnosno skladište B jer ima najmanju prosječnu udaljenost od trgovina. Zbog svega navedenoga prilagođava se proračun kako bi najveća težina dala najbolju alternativu.

Skladište A	$\begin{bmatrix} 20 \end{bmatrix}$	\rightarrow	$\begin{bmatrix} 56 / 20 \end{bmatrix}$	$=$	$\begin{bmatrix} 2,8 \end{bmatrix}$	\rightarrow	$\begin{bmatrix} 2,8 / 17,9667 \end{bmatrix}$	$=$	$\begin{bmatrix} 0,1558 \end{bmatrix}$
Skladište B	$\begin{bmatrix} 8 \end{bmatrix}$		$\begin{bmatrix} 56 / 8 \end{bmatrix}$		$\begin{bmatrix} 7 \end{bmatrix}$		$\begin{bmatrix} 7 / 17,9667 \end{bmatrix}$		$\begin{bmatrix} 0,3896 \end{bmatrix}$
Skladište C	$\begin{bmatrix} 12 \end{bmatrix}$		$\begin{bmatrix} 56 / 12 \end{bmatrix}$		$\begin{bmatrix} 4,6667 \end{bmatrix}$		$\begin{bmatrix} 4,6667 / 17,9667 \end{bmatrix}$		$\begin{bmatrix} 0,2597 \end{bmatrix}$
Skladište D	$\begin{bmatrix} 16 \end{bmatrix}$		$\begin{bmatrix} 56 / 16 \end{bmatrix}$		$\begin{bmatrix} 3,5 \end{bmatrix}$		$\begin{bmatrix} 3,5 / 17,9667 \end{bmatrix}$		$\begin{bmatrix} 0,1948 \end{bmatrix}$
	<u>56</u>				<u>17,9667</u>				

4.4.3.4. Prosječna udaljenost od dobavljača (km)

Skladište A	14	→	14 / 49	=	0,2857
Skladište B	10		10 / 49		0,2041
Skladište C	12		12 / 49		0,2449
Skladište D	13		13 / 49		0,2653
	49		1,0000		

Kao i u prethodnom slučaju, kao najbolje skladište je dobiveno skladište A, međutim u ovom primjeru je najbolja opcija zapravo skladište B, pa se proračun prilagođava.

Skladište A	14	→	49 / 14	=	3,5	→	3,5 / 16,2525	=	0,2154
Skladište B	10		49 / 10		4,9		4,9 / 16,2525		0,3015
Skladište C	12		49 / 12		4,0833		4,0833 / 16,2525		0,2512
Skladište D	13		49 / 13		3,7692		3,7692 / 16,2525		0,2319
	49		16,2525						

4.4.3.5. Fleksibilnost kretanja (0-4)

Skladište A	3	→	3 / 10	=	0,3
Skladište B	1		1 / 10		0,1
Skladište C	2		2 / 10		0,2
Skladište D	4		4 / 10		0,4
	10		1,0		

4.4.4. Određivanje konačnog rješenja [18]

	Cijena	Kapacitet	Trgovine	Dobavljači	Fleksibilnost	
Skladište A	0,2673	0,1818	0,1558	0,2154	0,3	0,2872
Skladište B	0,1871	0,2182	0,3896	0,3015	0,1	0,3469
Skladište C	0,2338	0,2727	0,2597	0,2512	0,2	0,1545
Skladište D	0,3118	0,3273	0,1948	0,2319	0,4	0,1545
						0,0569
					*	=
						0,2143
						0,2419
						0,2521
						0,2918

Skladište D predlaže se kao najbolji izbor od ponuđena četiri skladišta.

4.4.5. Provjera konzistentnosti [18]

Cijena	1	1	2	2	4	0,2872
Kapacitet	1	1	3	3	4	0,3469
Trgovine	0,5	0,3333	1	1	4	0,1545
Dobavljači	0,5	0,3333	1	1	4	0,1545
Fleksibilnost	0,25	0,25	0,25	0,25	1	0,0569
	3,25	2,9166	7,25	7,25	17	

Matrica odlučivanja

2. vektor prioriteta

$$\lambda_{\max} = 3,25 * 0,2872 + 2,9166 * 0,3469 + 7,25 * 0,1545 + 7,25 * 0,1545 + 17 * 0,0569 = 5,1527$$

$$CI = \frac{\lambda_{\max} - n}{n - 1} = \frac{5,1527 - 5}{5 - 1} = 0,0382$$

$$CR = \frac{CI}{RI} = \frac{0,0382}{1,12} = 0,0341 \approx 0,03 * 100 = 3\% < 10\%$$

λ_{\max} - maksimalna vrijednost matrice

CI - indeks konzistentnosti

n - broj redova matrice

CR - omjer konzistentnosti

RI - slučajni indeks konzistentnosti

S obzirom na to da je omjer konzistentnosti približno oko 3%, što je puno manje od dozvoljenih 10%, ovaj primjer je konzistentan.

4.5. Softverski alat expert choice 11 za rješavanje problema AHP metodom

Od 1983. godine, *expert choice* je vodeći softverski alat u grupnom odlučivanju. Koristi se u više od 30 vladinih agencija Sjedinjenih Američkih Država i preko 100 sveučilišta u više od 60 država. Uspješne vladine organizacije i kompanije u industriji koriste ovaj softverski alat zbog sve više dostupnih informacija, varijabli, dioničara ali i nedostatka vremena. On omogućuje brzo usklađivanje iskustva, intuicija i podataka kako bi se omogućila suradnja i donošenje odluka s povjerenjem. *Expert choice* predstavlja način odlučivanja koji se usklađuje s ciljem donositelja odluke. On pomaže poslovnim liderima u brzom donošenju odluka s ciljem boljih poslovnih rezultata, a u skladu s dugoročnom strategijom kompanije. Pored svega navedenog, ovaj softverski alat omogućuje razvoj zajedničkog jezika u donošenju odluka i standardiziranju analize procesa [19].



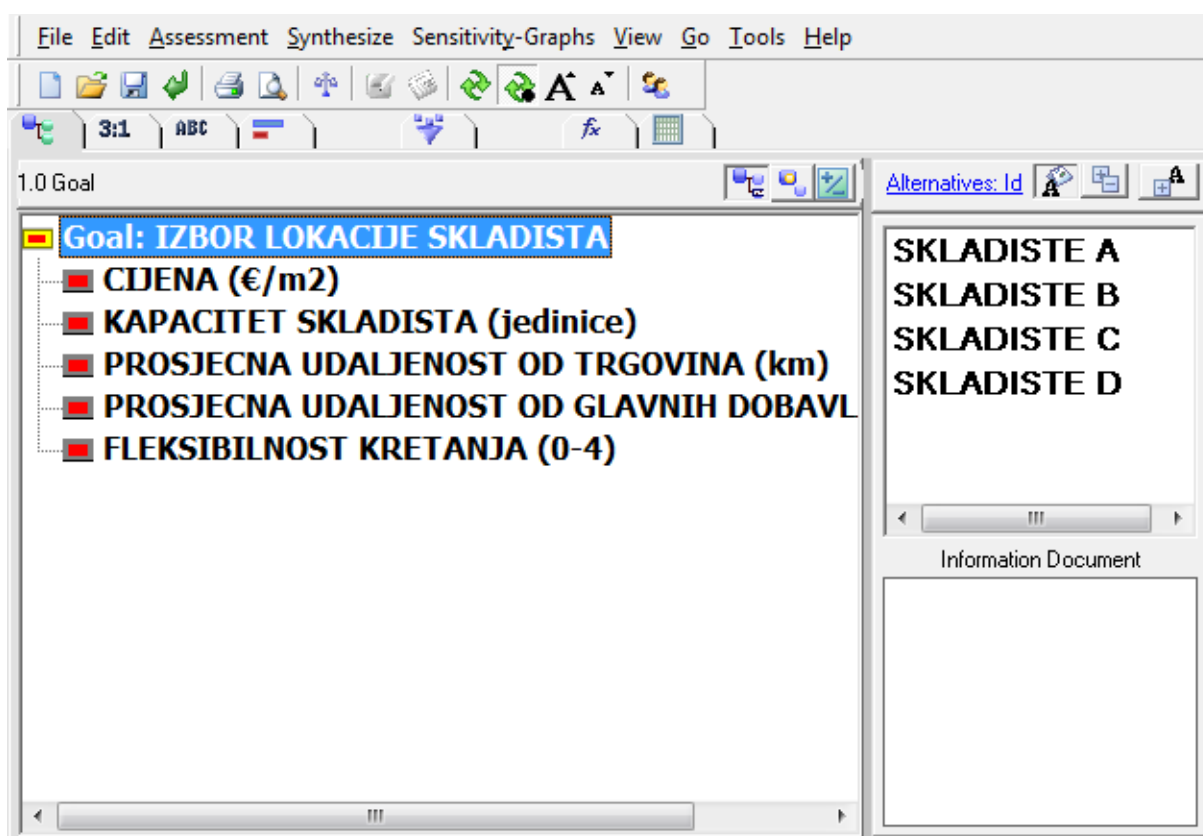
Slika 11. Logo softverskog alata expert choice [19]

Expert choice 11 je u potpunosti primjenjiv na AHP metodu i podržava sve potrebne korake. On omogućuje strukturiranje problema te uspoređivanje kriterija i alternativa u parovima, na više načina. Pored usporedbe u parovima, omogućuje i direktni unos kvantitativnih podataka. *Expert choice 11* ima mogućnost analize osjetljivosti rezultata, koja se temelji na jednostavnom načinu izmjene relativnih važnosti (težina) kriterija i alternativa. Više o navedenom softveru, kao i prikaz načina funkcioniranja na primjeru, može se vidjeti u točki 5. ovog diplomskog rada.

5. ODABIR LOKACIJE SKLADIŠTA PRIMJENOM AHP METODE U EXPERT CHOICE-u

Primjer problema odabira lokacije skladišta koji će se rješavati AHP metodom u softverskom alatu *expert choice* dan je u tablici 2.

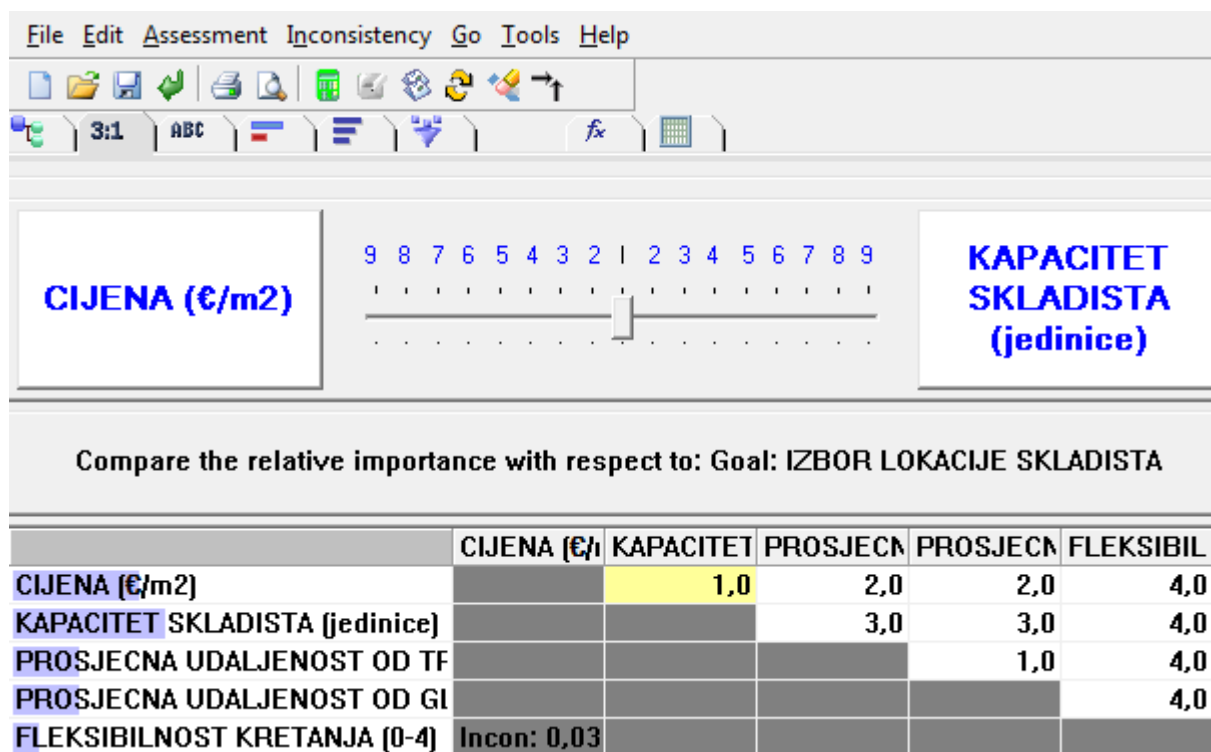
Struktura problema s ciljem (izbor lokacije skladišta) na vrhu, kriterijima (cijena, kapacitet skladišta, prosječna udaljenost od trgovina, prosječna udaljenost od glavnih dobavljača, fleksibilnost kretanja) na nižoj razini te alternativama (skladište A, skladište B, skladište C, skladište D) na dnu modela, može se vidjeti na slici 12.



Slika 12. Struktura problema s kriterijima i alternativama

Nakon strukturiranja problema, provodi se usporedba kriterija u parovima kako bi se odredio najznačajniji kriterij. Ta usporedba u softverskom alatu *expert choice* može se provoditi na tri različita načina:

- Usporedba u parovima prema Saatyjevoj skali [Slika 13]
- Usporedba u parovima prema Saatyjevoj skali s obzirom na važnost [Slika 14].
- Usporedba u parovima s obzirom na grafički prikaz [Slika 15].



Slika 13. Usporedba kriterija u parovima prema Saatyjevoj skali

Kao najznačajniji kriterij je dobiven kapacitet skladišta, a iza njega slijedi cijena. Omjer konzistentnosti je približno 0,03 odnosno 3% što je manje od dozvoljenih 10%, pa je primjer konzistentan.

File Edit Assessment Inconsistency Go Tools Help

3:1 ABC

CIJENA (€/m²)

Compare the relative importance with respect to: Goal: IZBOR LOKACIJE SKLADISTA

KAPACITET SKLADISTA (jedinice)

- Extreme
- Very Strong
- Strong
- Moderate
- Equal
- Moderate
- Strong
- Very Strong
- Extreme

	CIJENA (€/m ²)	KAPACITET	PROSJEČN	PROSJEČN	FLEKSIBIL
CIJENA (€/m ²)		1,0	2,0	2,0	4,0
KAPACITET SKLADISTA (jedinice)			3,0	3,0	4,0
PROSJEČNA UDALJENOST OD				1,0	4,0
PROSJEČNA UDALJENOST OD					4,0
FLEKSIBILNOST KRETANJA (0	Incon: 0,03				

Slika 14. Usporedba kriterija u parovima prema Saatyjevoj skali s obzirom na važnost


File Edit Assessment Inconsistency Go Tools Help

3:1 ABC

CIJENA (€/m²)

Compare the relative importance with respect to: Goal: IZBOR LOKACIJE SKLADISTA

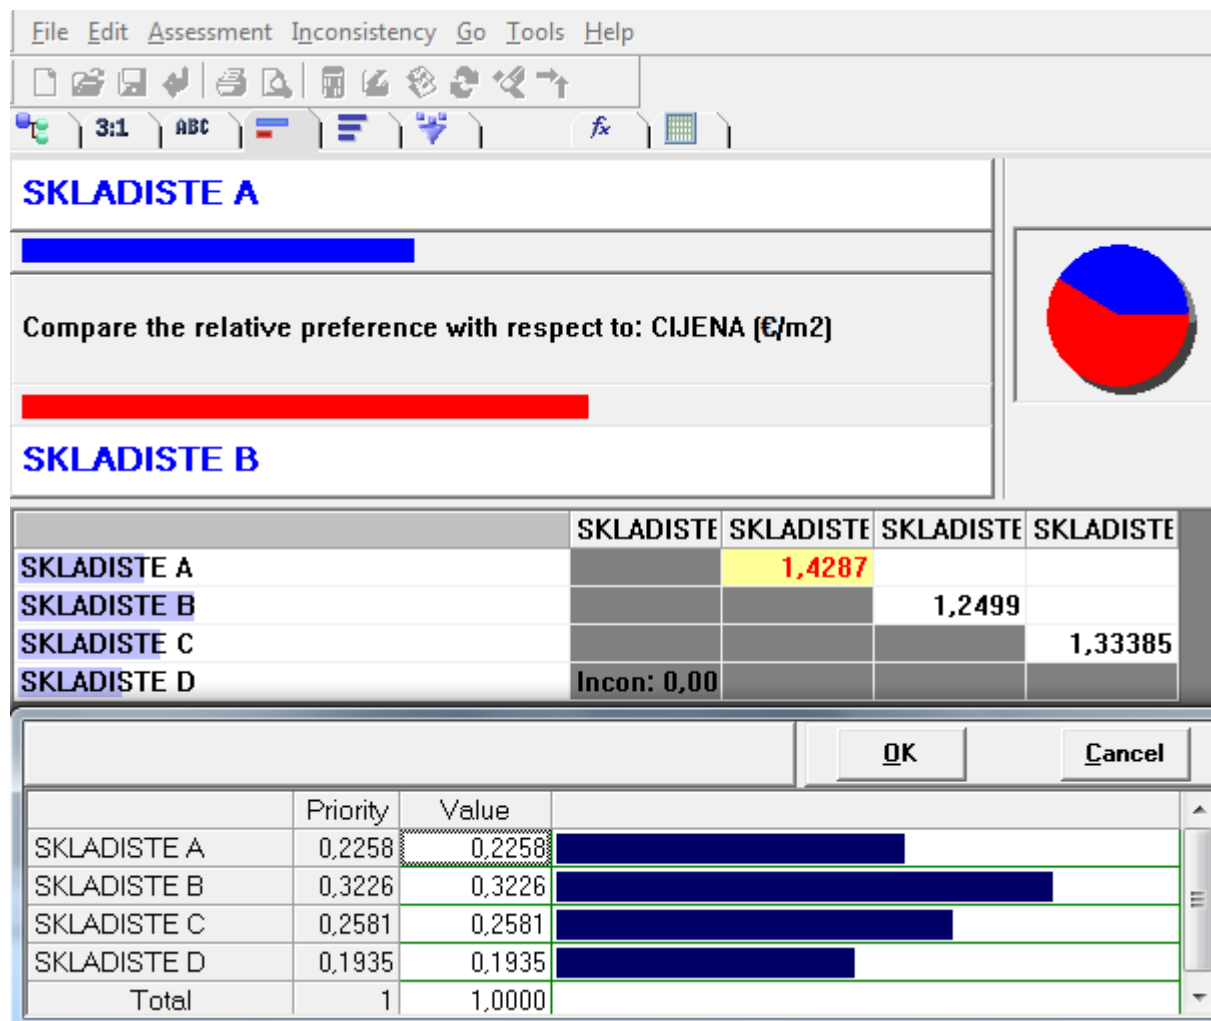
KAPACITET SKLADISTA (jedinice)



	CIJENA (€/m ²)	KAPACITET	PROSJEČN	PROSJEČN	FLEKSIBIL
CIJENA (€/m ²)		1,0	2,0	2,0	4,0
KAPACITET SKLADISTA (jedinice)			3,0	3,0	4,0
PROSJEČNA UDALJENOST OD				1,0	4,0
PROSJEČNA UDALJENOST OD					4,0
FLEKSIBILNOST KRETANJA (0	Incon: 0,03				

Slika 15. Usporedba kriterija u parovima s obzirom na grafički prikaz

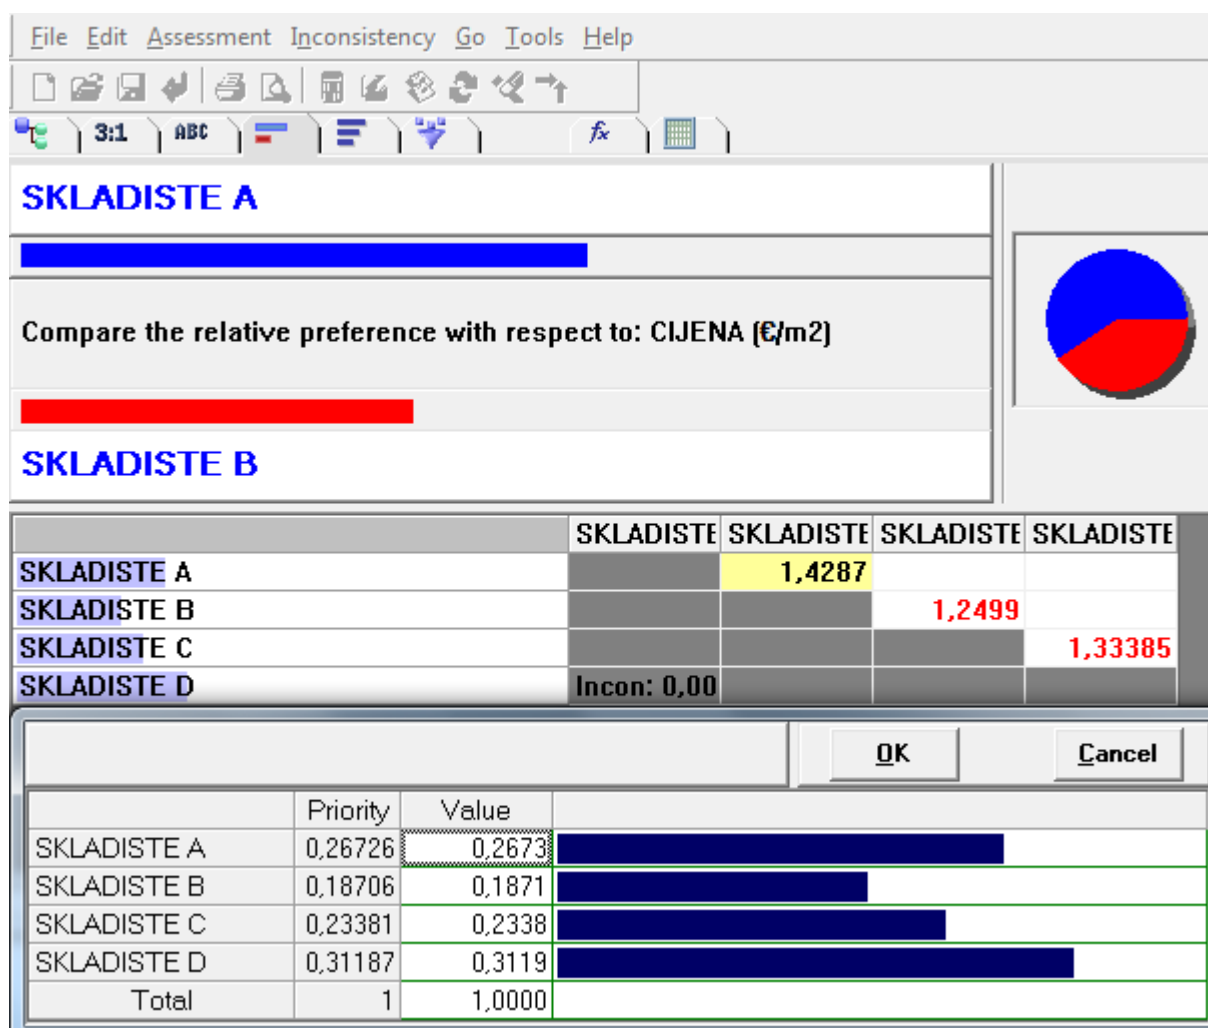
Nakon usporedbe kriterija u parovima i određivanja najznačajnijeg, provodi se usporedba alternativa u parovima s obzirom na pojedini kriterij. Kao početni kriterij uzima se cijena (€/m^2). S obzirom na to da za svaku alternativu postoje kvantitativne vrijednosti, usporedba alternativa se ne radi kao kod kriterija. Prvo se provodi normalizacija podataka kako bi njihova suma iznosila 1, vidljivo u točki 4.4.3.1, te se naknadno unose u prozor koji se pojavljuje otvaranjem padajućeg izbornika *Assessment* i odabira opcije *Direct* [Slika 16].



Slika 16. Usporedba alternativa u parovima s obzirom na cijenu

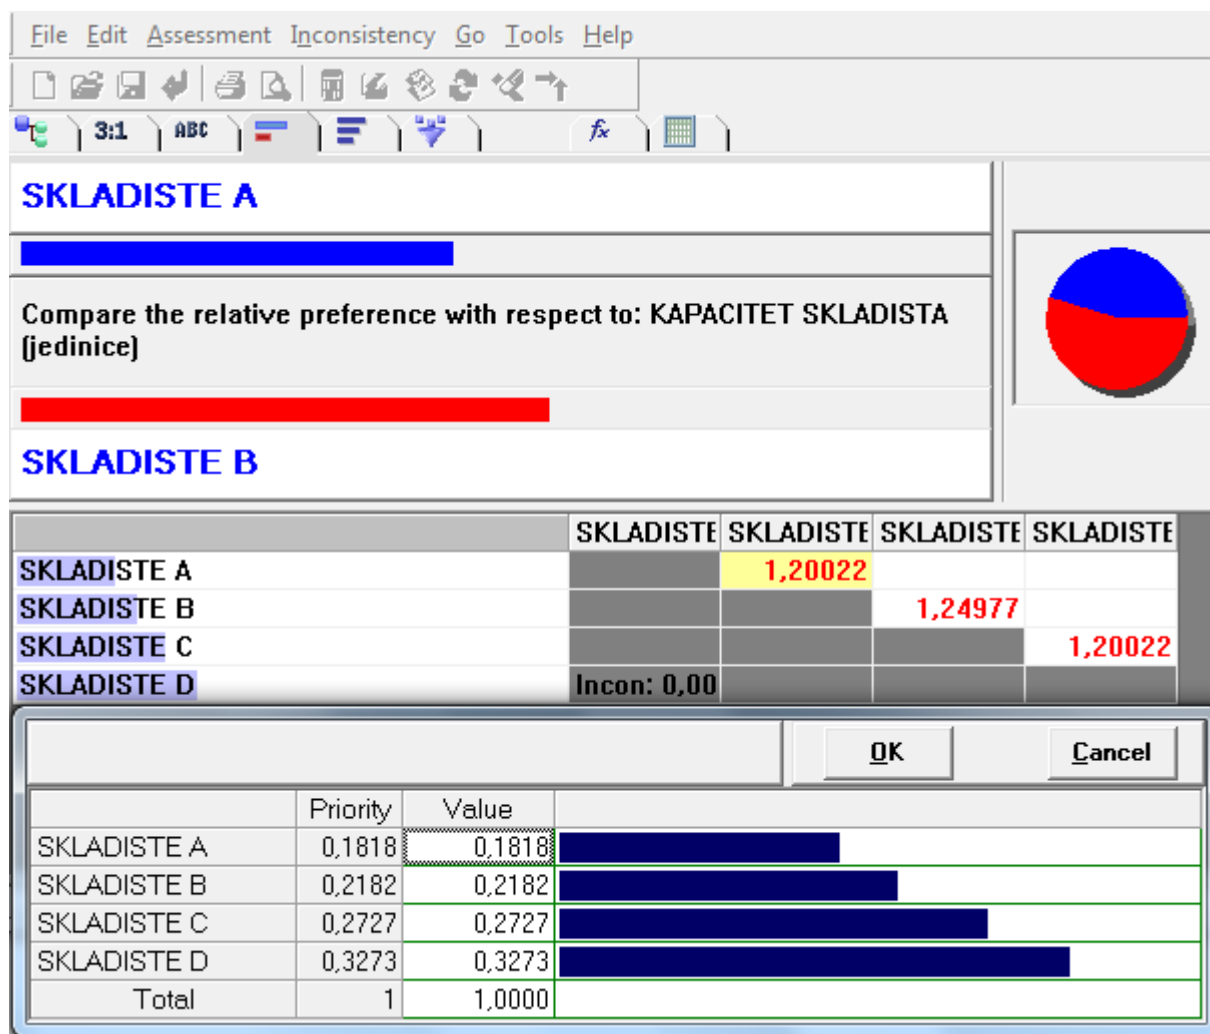
S obzirom na to da upisane vrijednosti kao najznačajniju alternativu daju skladište B koje je zapravo najskuplje, odnosno najnepovoljnije skladište, potrebno je izvršiti invertiranje podataka. Ono se provodi pritiskom na tipku *Invert* koja se nalazi točno ispod padajućeg izbornika *Go*.

Nakon provedenog invertiranja, sve crvene vrijednosti postaju crne i obrnuto. Kao najznačajnija alternativa s obzirom na cijenu, dobiva se skladište D koje je ujedno i najjeftinije. Otvaranjem padajućeg izbornika *Assessment* i odabirom opcije *Direct* otvara se prozor u kojem se mogu vidjeti dobivene vrijednosti težina alternativa nakon invertiranja [Slika 17]. Vrijednosti dobivene nakon invertiranja u softverskom alatu *expert choice*, mogu se usporediti s vrijednostima dobivenim u točki 4.4.3.1 nakon prilagodbe proračuna.



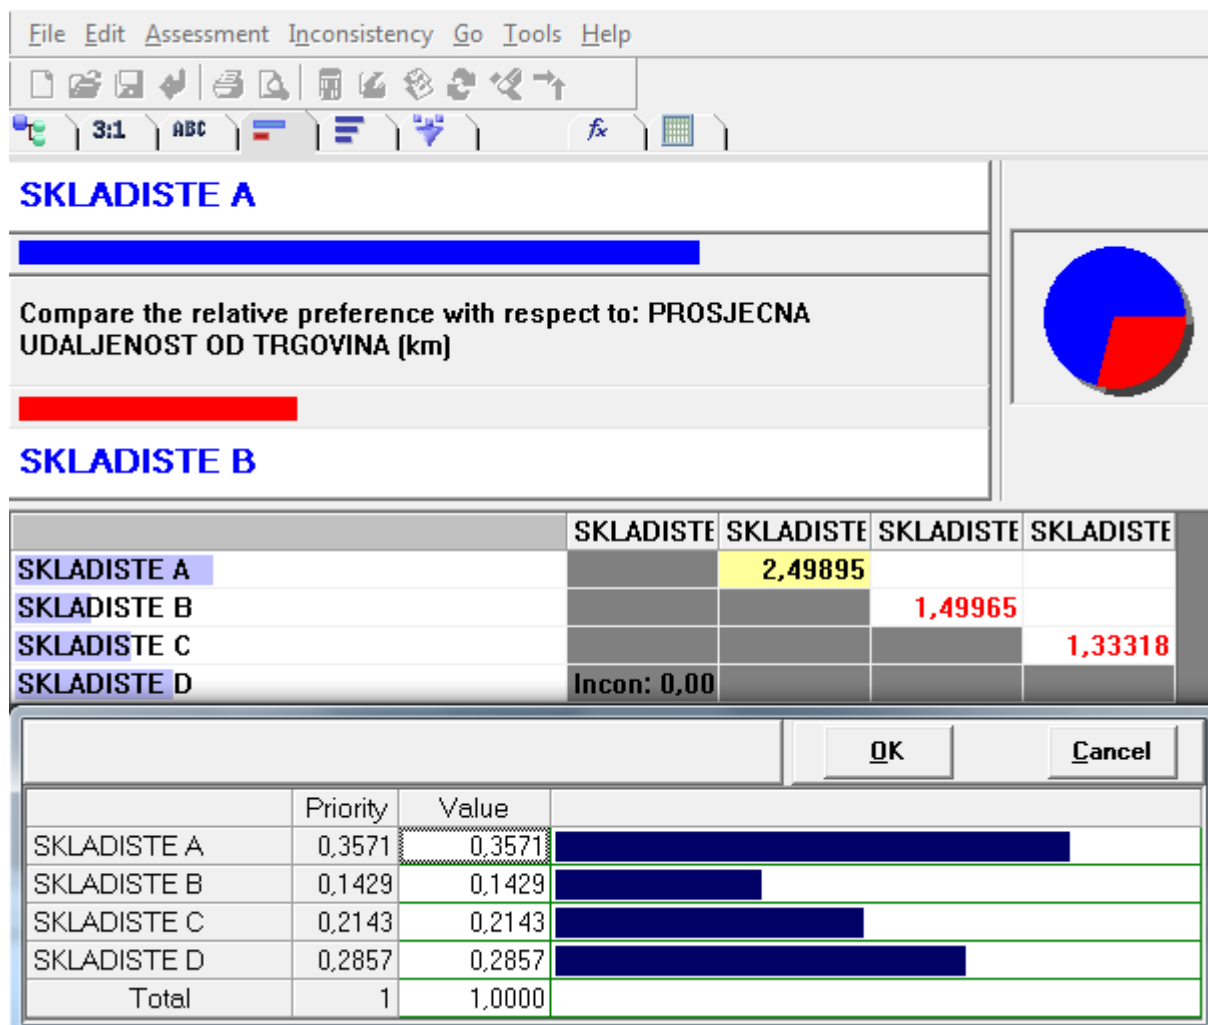
Slika 17. Usporedba alternativa u parovima s obzirom na cijenu, nakon invertiranja

Za idući kriterij uzima se kapacitet skladišta (jedinice). Otvaranjem padajućeg izbornika *Assessment* i odabira opcije *Direct* otvara se prozor u koji se unose vrijednosti dobivene nakon normalizacije podataka. Postupak normalizacije je prikazan u točki 4.4.3.2. Kao najznačajnija alternativa s obzirom na kapacitet skladišta, dobiva se skladište D koje ujedno ima i najveći kapacitet skladišta [Slika 18].



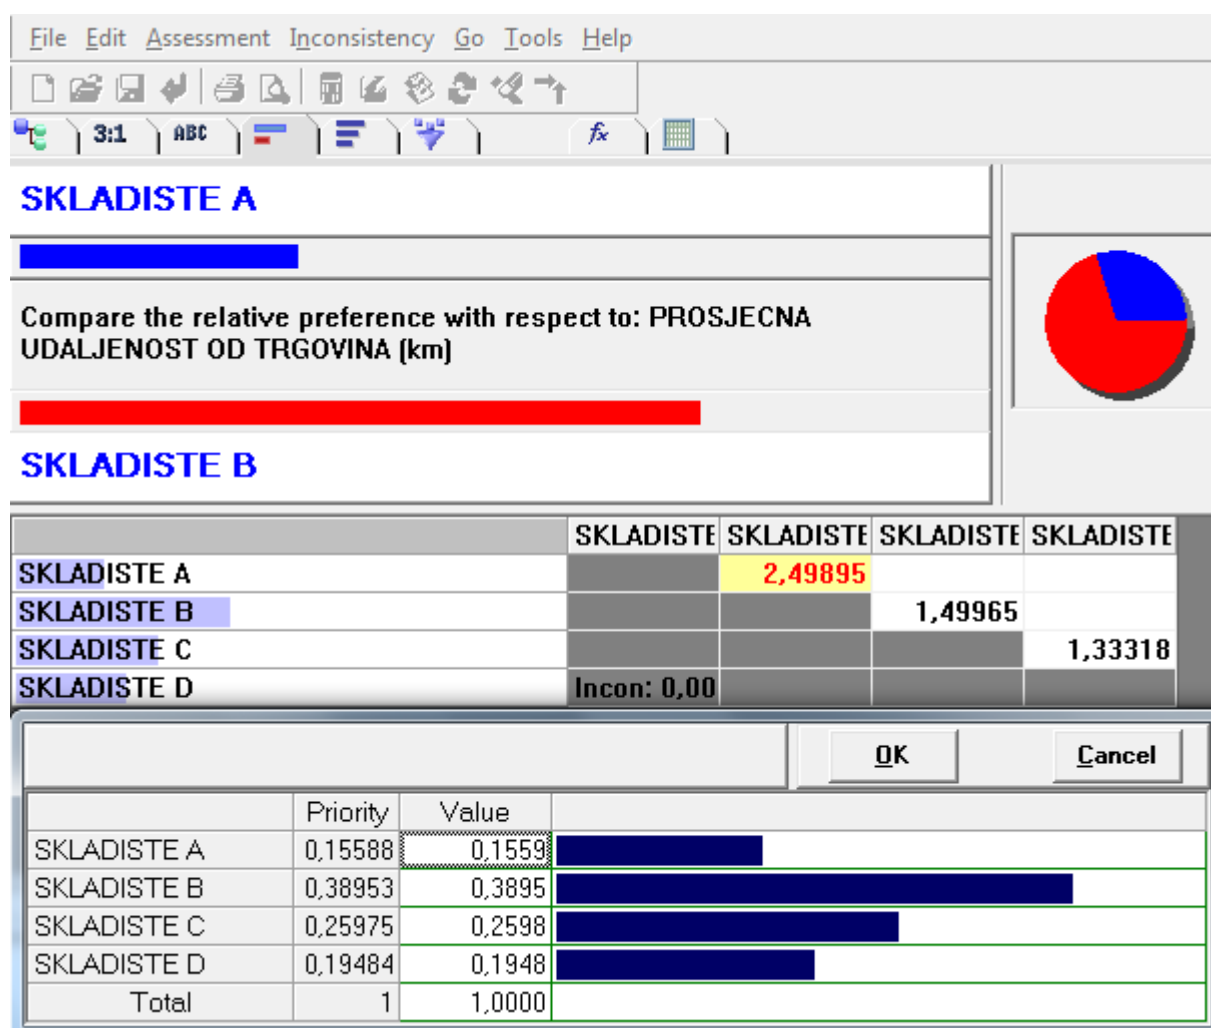
Slika 18. Usporedba alternativa u parovima s obzirom na kapacitet skladišta

Prosječna udaljenost od trgovina (km), uzima se kao sljedeći kriterij. Kako bi se dobila najznačajnija alternativa, obzirom na prosječnu udaljenost od trgovina, u prozor se unose vrijednosti dobivene nakon normalizacije podataka, vidljive u točki 4.4.3.3. Prozor se pojavljuje otvaranjem padajućeg izbornika *Assessment* te pritiskom na opciju *Direct*. Kao najznačajnija alternativa s obzirom na prosječnu udaljenost od trgovina, dobiva se skladište A, koje ustvari ima najveću udaljenost [Slika 19].



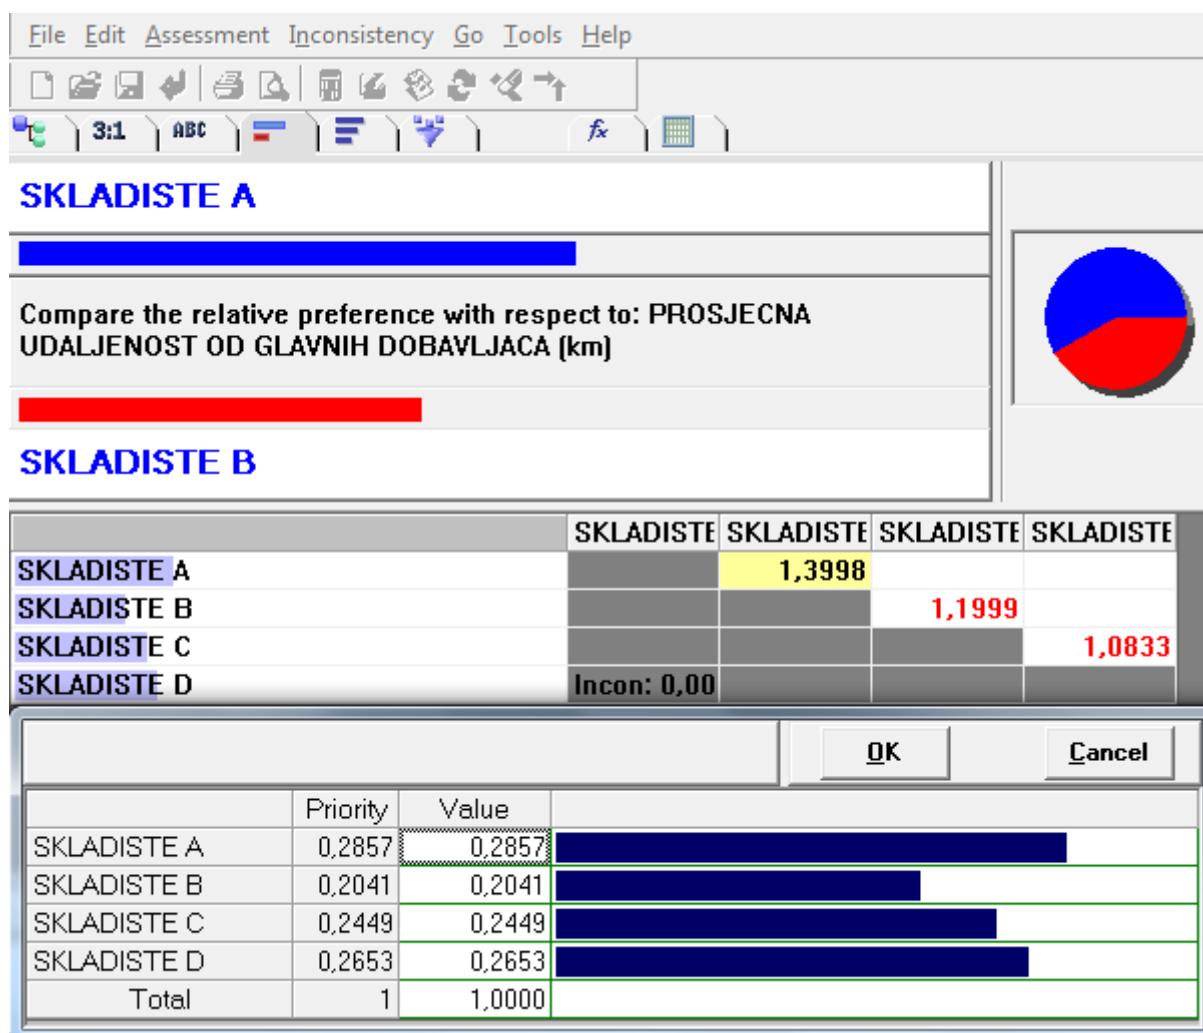
Slika 19. Usporedba alternativa u parovima s obzirom na prosječnu udaljenost od trgovina

S obzirom na to da AHP metoda uzima najveću težinu prioriteta ujedno i kao najvažniju, da bi se kao najvažnije skladište dobilo ono s najmanjom udaljenosti od trgovina, potrebno je provesti invertiranje podataka. Ono se provodi pritiskom na tipku *Invert* koja se nalazi točno ispod padajućeg izbornika *Go*. Nakon provedenog invertiranja, sve crne vrijednosti postaju crvene i obrnuto. Kao najznačajnija alternativa s obzirom na udaljenost od trgovina, dobiva se skladište B koje je ujedno i ima najmanju prosječnu udaljenost od trgovina.

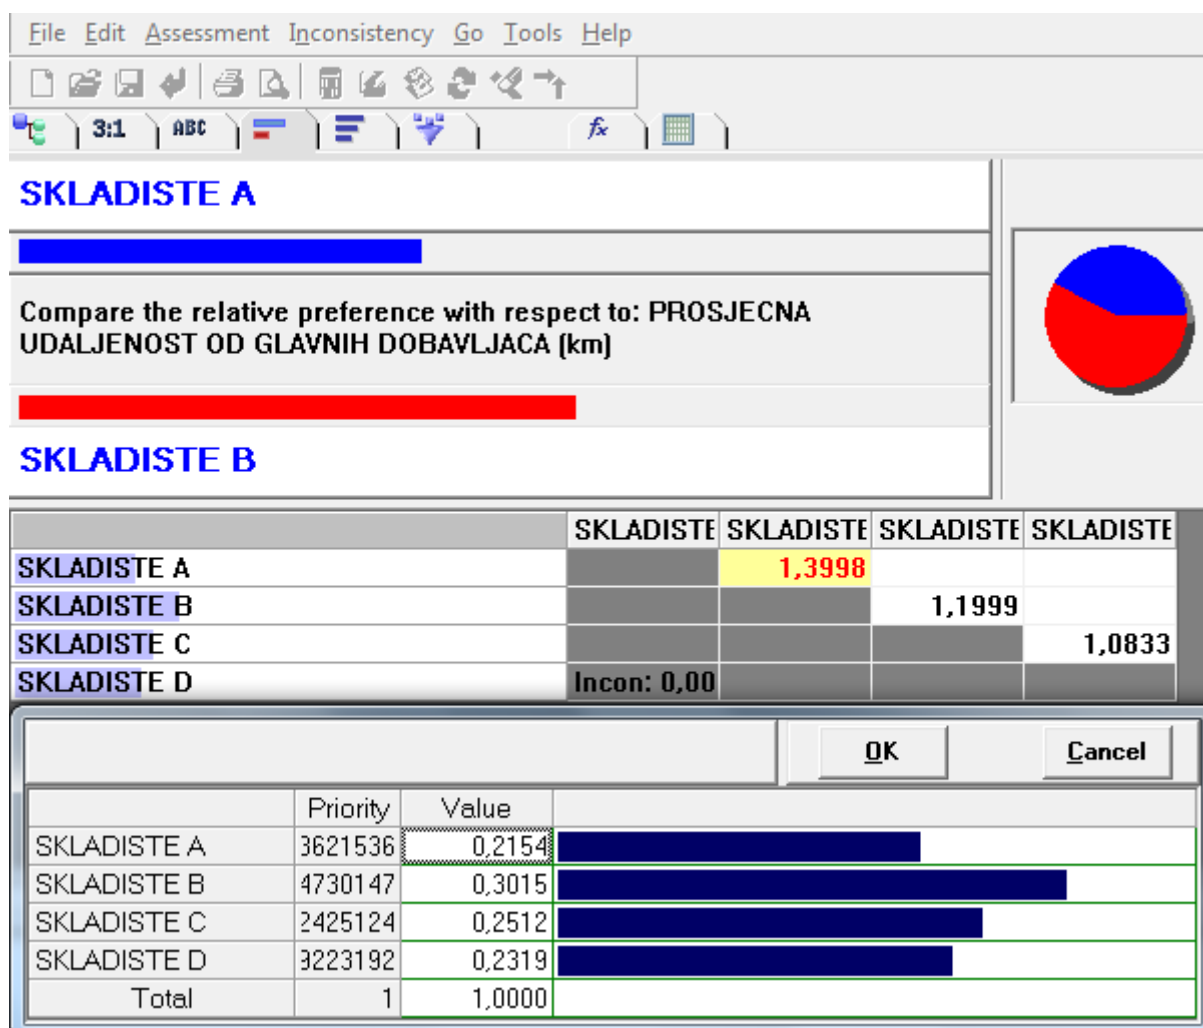


Slika 20. Usporedba alternativa u parovima s obzirom na prosječnu udaljenost od trgovina, nakon invertiranja

Sličan postupak kao za kriterij prosječna udaljenost od trgovina, provodi se i za kriterij prosječna udaljenost od glavnih dobavljača. Prvo se unose normalizirane vrijednosti, vidljive u točki 4.4.3.4. One kao najznačajniju alternativu daju skladište A, koje ustvari ima najveću prosječnu udaljenost od glavnih dobavljača [Slika 21]. Zbog toga se provodi postupak invertiranja podataka kako bi se kao najznačajnija alternativa, dobila ona s najmanjom prosječnom udaljenosti od glavnih dobavljača, odnosno skladište B [Slika 22]

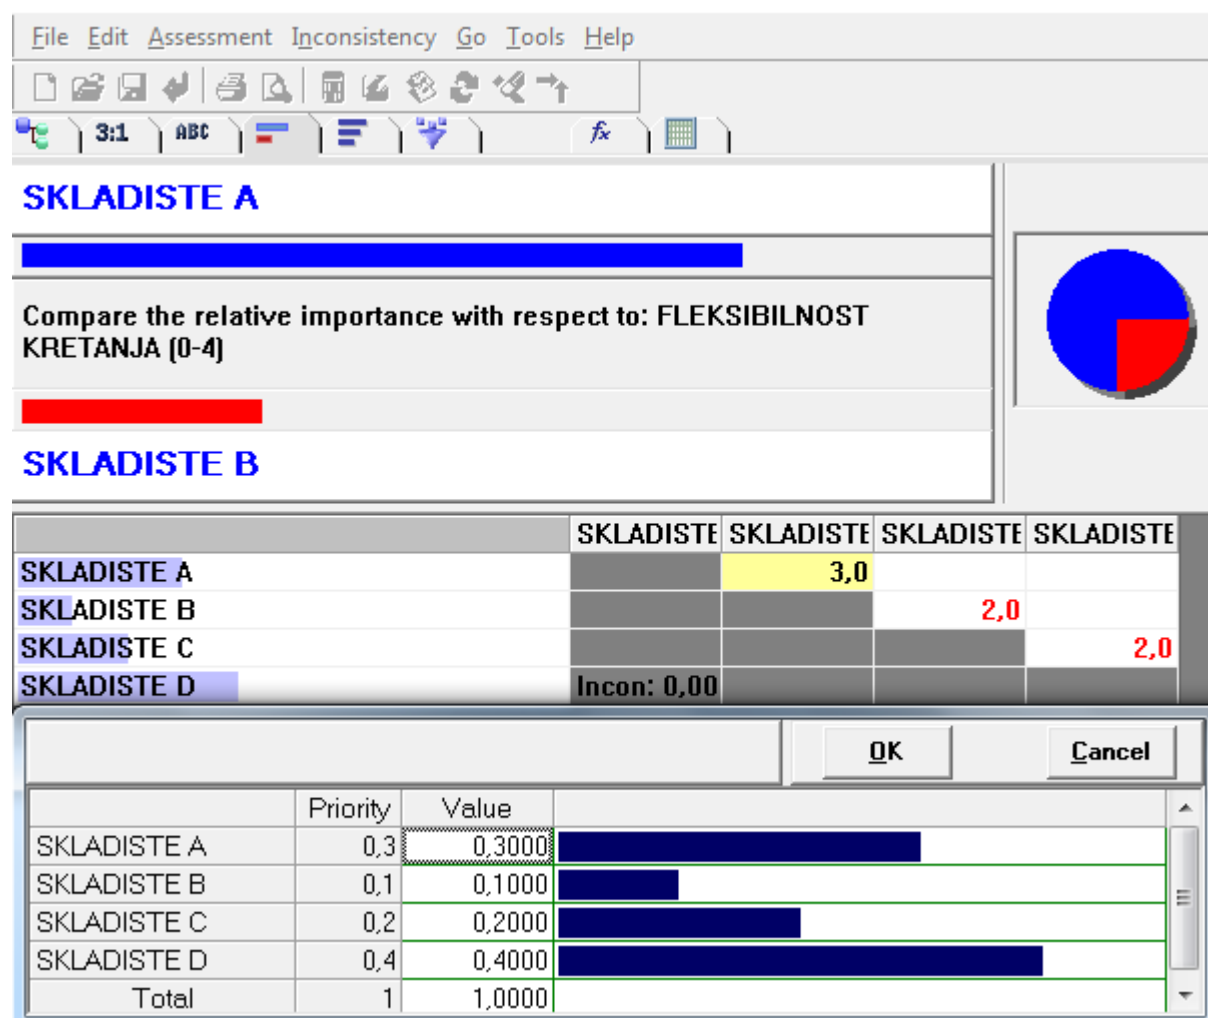


Slika 21. Usporedba alternativa u parovima s obzirom na prosječnu udaljenost od glavnih dobavljača



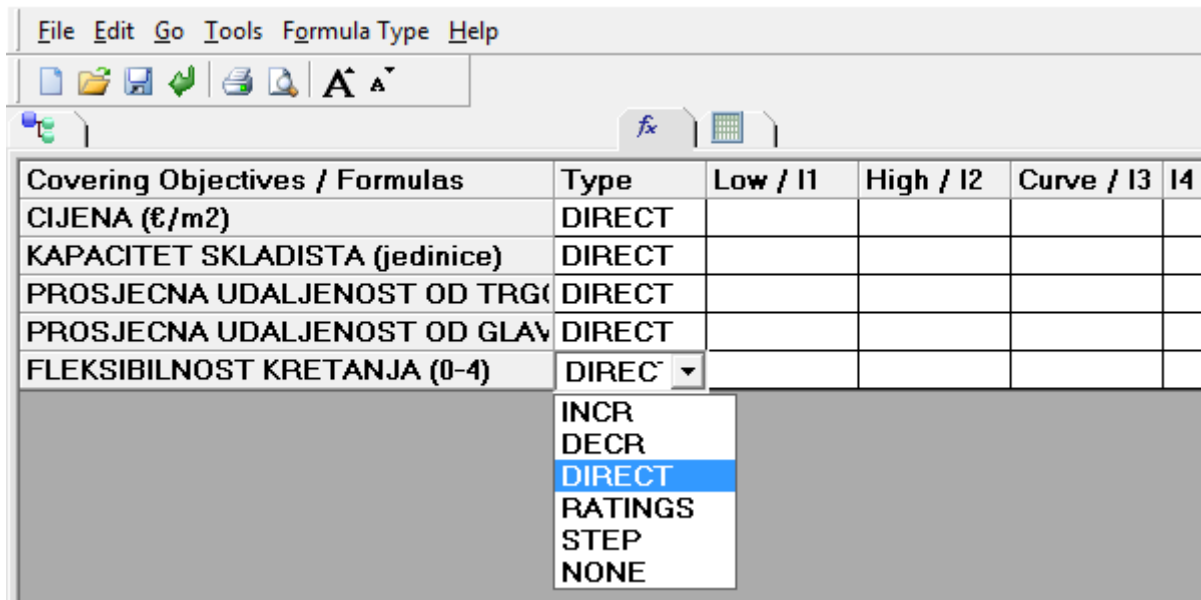
Slika 22. Usporedba alternativa u parovima s obzirom na prosječnu udaljenost od glavnih dobavljača, nakon invertiranja

Kao posljednji kriterij uzima se fleksibilnost kretanja (0-4), gdje 0 označava najmanju fleksibilnost kretanja dok 4 označava najveću fleksibilnost kretanja unutar skladišta. Provodi se normalizacija podataka za svaku alternativu, kako bi njihova suma iznosila 1, vidljivo u točki 4.4.3.5. Dobivene vrijednosti se unose u program, te se kao najznačajnija alternativa dobiva skladište s najvećom fleksibilnošću, skladište D [Slika 23].



Slika 23. Usporedba alternativa u parovima s obzirom na fleksibilnost kretanja

Osim prethodnog načina usporedbe alternativa i unošenja vrijednosti težina alternativa za svaki kriterij pojedinačno, unos svih podataka se mogao napraviti odjednom. Da bi se ovakav način unosa podataka omogućio, trebalo je odabrati opciju *Formulas Grid* te za svaki kriterij pojedinačno pod *Type* odabrati *DIRECT* [Slika 24].



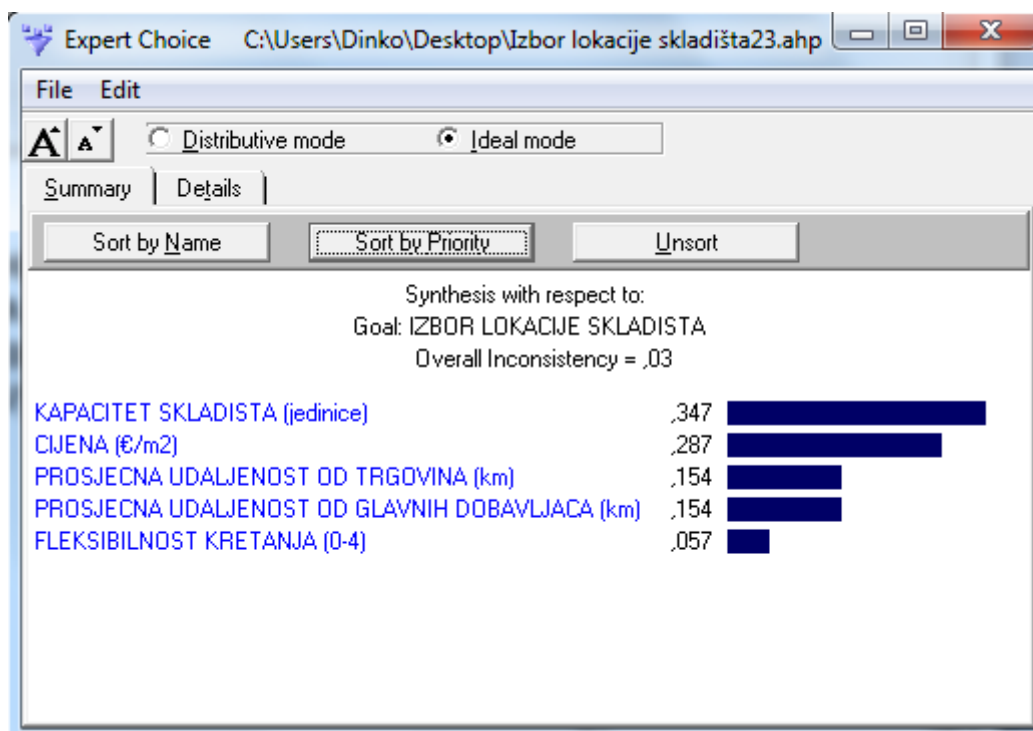
Slika 24. Definiranje formule direktnog unosa podataka

Nakon toga se odabire opcija *Data Grid* i otvara se prozor u koji se unose podaci [Slika 25]. U ovom slučaju, trebalo je paziti na normalizirane vrijednosti podataka koji se unose, kako najveća težina ne bi dala najlošiju alternativu, vidjeti točku 4.4.3.1.

File Edit Assessment View Go Plot Tools Formula Type Mapping Help						
Ideal mode						
Alternative	CIJENA (€/m2) (L: .287)	KAPACITET SKLADISTA (jedinice) (L: .347)	PROSJEKNA UDALJENOST OD TRGOVINA (km) (L: .154)	PROSJEKNA UDALJENOST OD GLAVNIH DOBAVLJACA (km) (L: .154)	FLEKSIBILNOST KRETANJA (0-4) (L: .057)	
<input checked="" type="checkbox"/> SKLADISTE A	0,2673	0,1818	0,1558	0,2154	0,3	
<input checked="" type="checkbox"/> SKLADISTE B	0,1871	0,2182	0,3896	0,3015	0,1	
<input checked="" type="checkbox"/> SKLADISTE C	0,2338	0,2727	0,2597	0,2512	0,2	
<input checked="" type="checkbox"/> SKLADISTE D	0,3118	0,3273	0,1948	0,2319	0,4	


Slika 25. Unos normaliziranih vrijednosti podataka

Kao najznačajniji kriterij dobiven je kapacitet skladišta, a odmah iza njega slijedi cijena. Ta dva kriterija sudjeluju s preko 60% u odabiru lokacije skladišta [Slika 26].



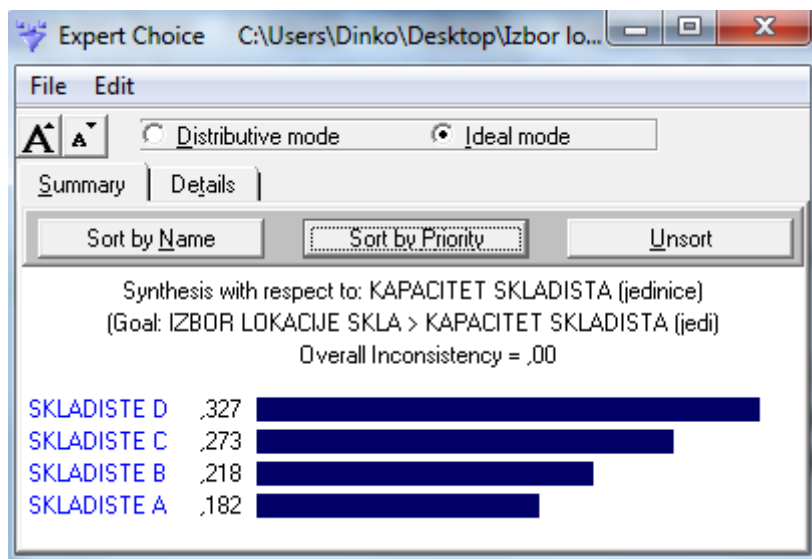
Slika 26. Relativne važnosti (težine) kriterija

Najznačajnija alternativa s obzirom na kriterij cijene je skladište D, odmah iza njega slijedi skladište A [Slika 27].




Slika 27. Prioriteti alternativa s obzirom na cijenu

Najznačajnija alternativa s obzirom na kriterij kapaciteta skladišta je skladište D, odmah iza njega slijedi skladište C [Slika 28].



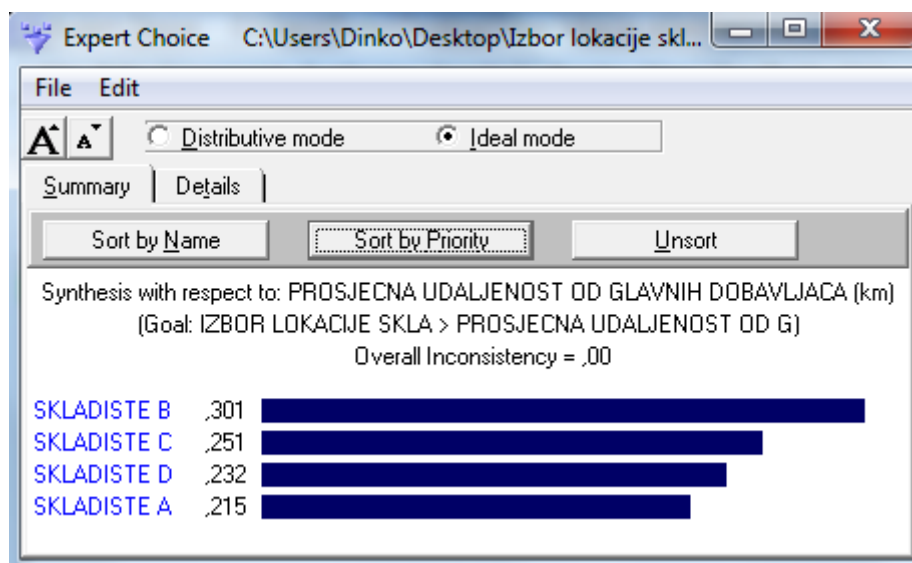
Slika 28. Prioriteti alternativa s obzirom na kapacitet skladišta

Najznačajnija alternativa s obzirom na kriterij prosječne udaljenosti od trgovina je skladište B, odmah iza njega slijedi skladište C [Slika 29].




Slika 29. Prioriteti alternativa s obzirom na prosječnu udaljenost od trgovina

Najznačajnija alternativa s obzirom na kriterij prosječne udaljenosti od glavnih dobavljača je skladište B, odmah iza njega slijedi skladište C [Slika 30].



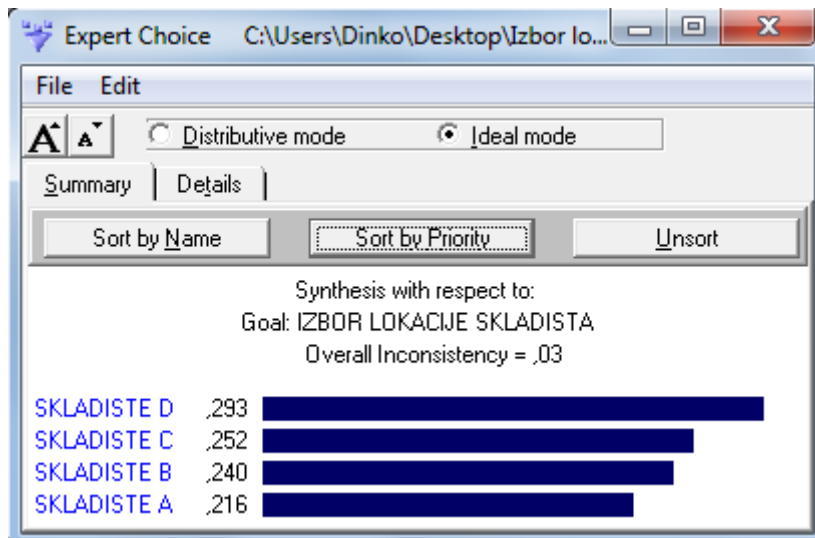
Slika 30. Prioriteti alternativa s obzirom na prosječnu udaljenost od glavnih dobavljača

Najznačajnija alternativa s obzirom na kriterij fleksibilnosti kretanja je skladište D, odmah iza njega slijedi skladište A [Slika 31].



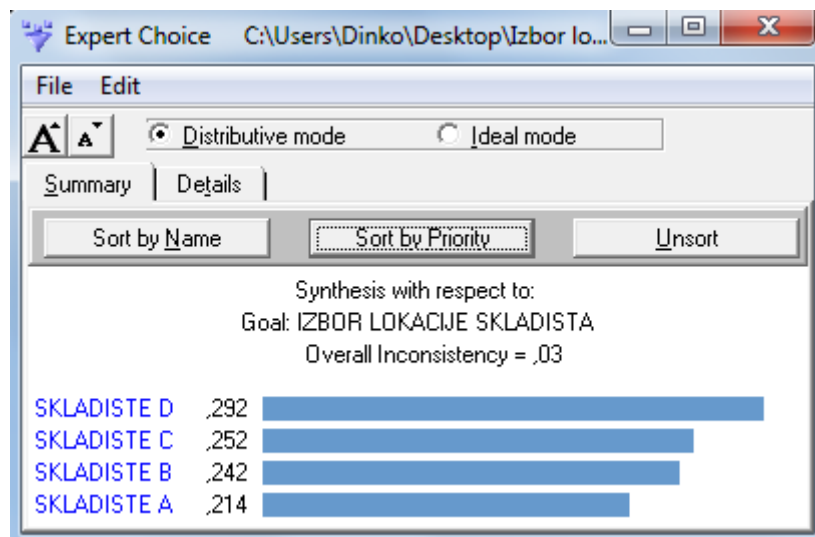
Slika 31. Prioriteti alternativa s obzirom na fleksibilnost kretanja

Konačni rezultati izbora lokacije skladišta prikazani su na slici 32. Kao najbolja lokacija dobivena je lokacija skladišta D, iza nje slijede lokacije skladišta C, skladišta B te skladište A. To se moglo i očekivati s obzirom na to da je za najznačajnije kriterije (kapacitet skladišta i cijena) skladište D imalo najveće težine.



Slika 32. Ukupni prioriteti alternativa (idealni način)


Osim idealnog načina (*ideal mode*) koji je odabran automatski nakon otvaranja programa *expert choice*, postoji još i distributivni način (*distributive mode*) rada, koji u konačnici daje malo drugačije rezultate [Slika 33]. Rezultati dobiveni distributivnim načinom podudaraju se s rezultatima dobivenim u točki 4.4.4.



Slika 33. Ukupni prioriteti alternativa (distributivni način)

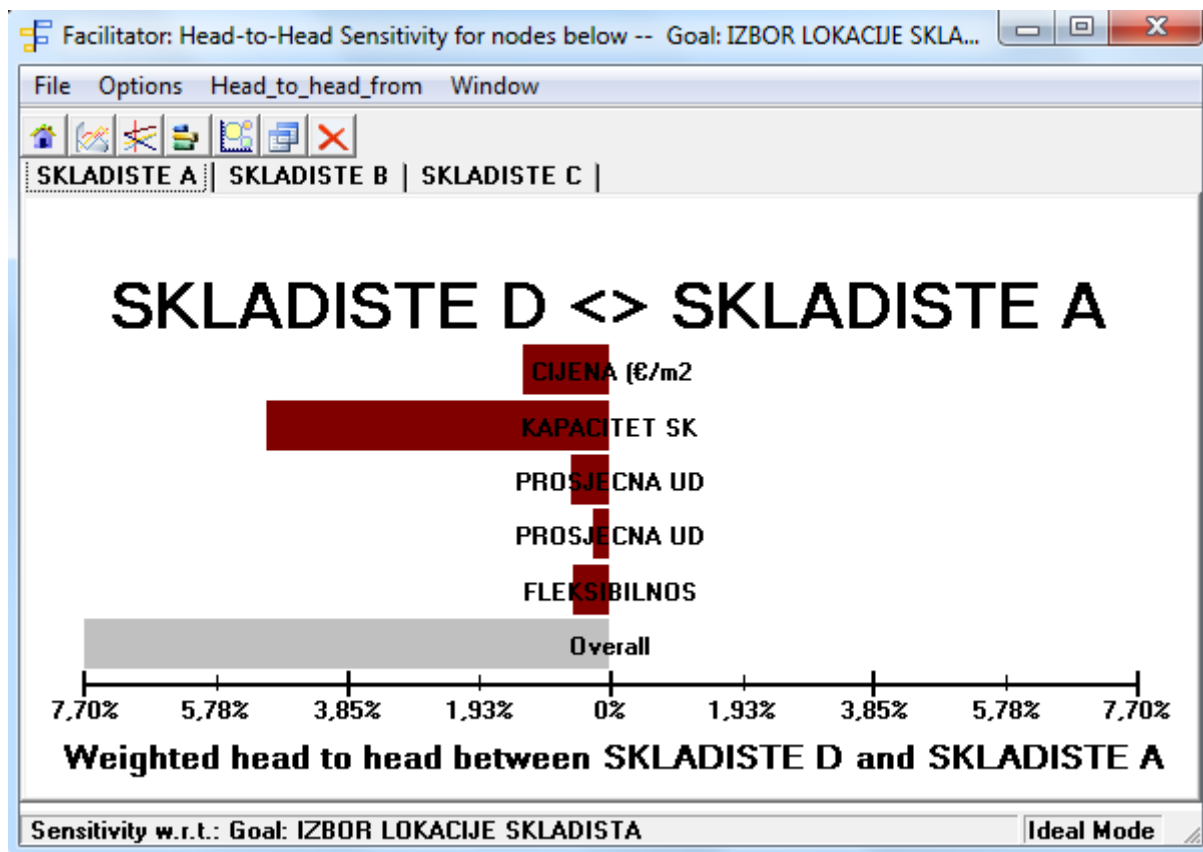
Razlika između ova dva načina je u tome što idealni način rada provodi normalizaciju tako da rezultat svake alternative dijeli samo s rezultatom najbolje alternative unutar svakog kriterija, dok distributivni način rada normalizira rezultate alternativa unutar svakog kriterija tako da njihova suma daje 1. Idealni način zadržava postojeće rangiranje dok kod distributivnog načina postoji potencijal za promjenom ranga [20].

Slika 34. prikazuje prioritete alternativa u 2D grafu s obzirom na dva najznačajnija kriterija, na x-osi nalazi se kapacitet skladišta a na y-osi nalazi se cijena. Iz slike se može vidjeti kako je najbolja alternativa za navedene kriterije skladište D, a iza slijede skladište A, skladište C i skladište B. Iako je skladište D i u ovom slučaju najbolja alternativa, ostatak redoslijeda se ipak razlikuje od konačnih rezultata izbora lokacije skladišta, prikazanih na slici 33.

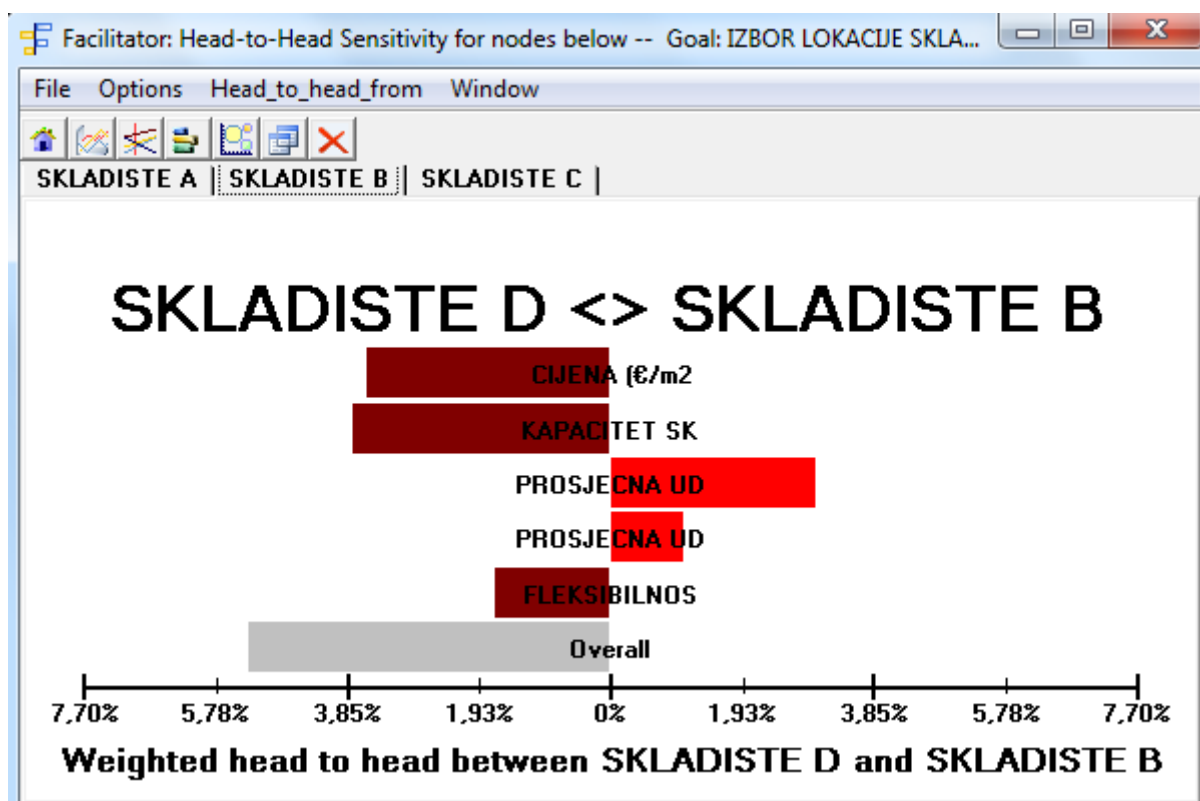


Slika 34. Prioriteti alternativa u 2D grafu

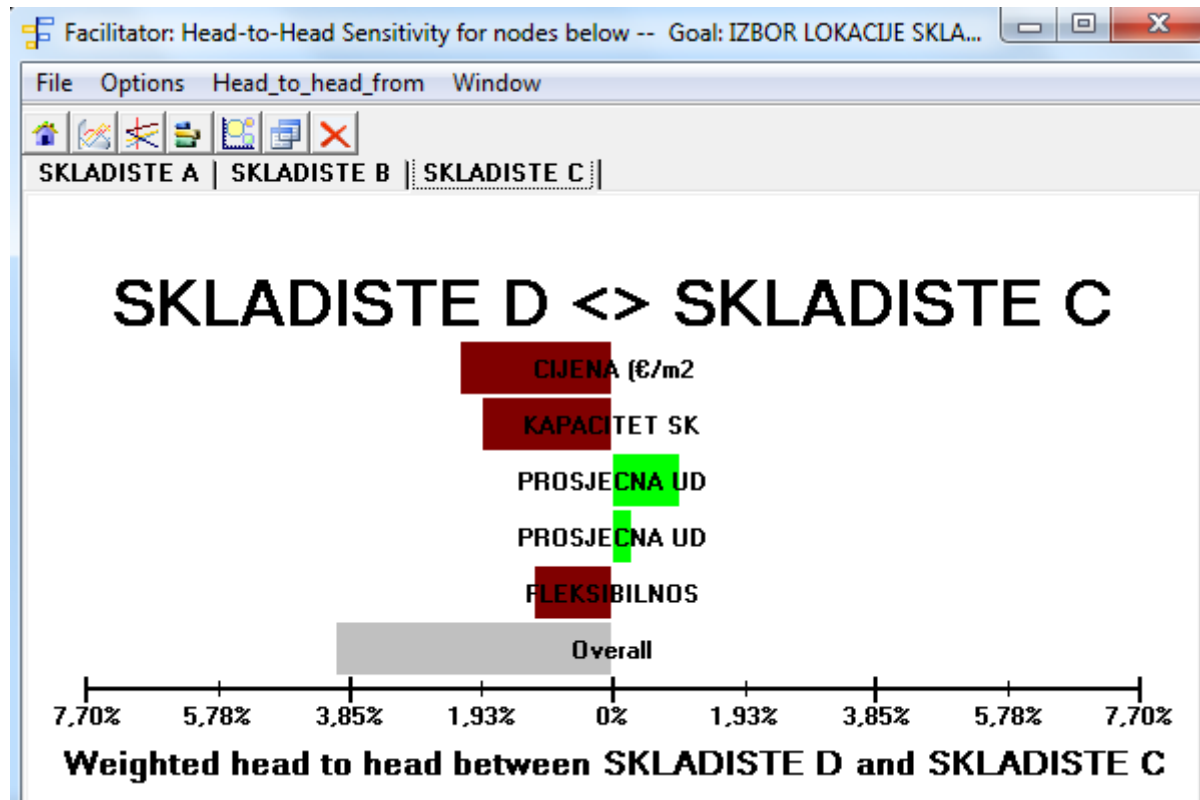
Na slikama 35., 36. i 37. mogu se vidjeti grafovi usporedbe najbolje alternative odnosno skladišta D, sa svim ostalim alternativama pojedinačno. Može se vidjeti kako je skladište D bolja alternativa od svih ostalih skladišta po kriterijima: cijena, kapacitet skladišta i fleksibilnost kretanja. Skladišta B i C bolje su alternative od skladišta D samo po kriterijima prosječne udaljenosti od trgovina i prosječne udaljenosti od glavnih dobavljača. Skladište A daleko je najgora alternativa s obzirom na to da je po svim kriterijima lošije od skladišta D.



Slika 35. Graf usporedbe skladišta D i skladišta A



Slika 36. Graf usporedbe skladišta D i skladišta B



Slika 37. Graf usporedbe skladišta D i skladišta C

6. ANALIZA OSJETLJIVOSTI REZULTATA

Primjer koji se obradio u softverskom alatu *expert choice* preuzet je iz znanstvenog članka [5]. S ciljem usporedbe AHP metode s ostalim metodama (TOPSIS, ELECTRE, *grey theory*) korigirano je subjektivno donošenje preferencija na Saatyjevoj skali [Slika 10., 13.], te su preferencije "namještene" kako bi se dobile otprilike jednake relativne važnosti (težine) kriterija kao u znanstvenom članku [Slika 26]. Relativne važnosti (težine) kriterija korištenih u navedenim metodama su gotovo identične $\{W_C, W_{KS}, W_{UT}, W_{UGD}, W_{FK}\} \approx (0.29, 0.35, 0.15, 0.15, 0.06)$. Gdje su: W_C težina kriterija cijene, W_{KS} težina kriterija kapaciteta skladišta, W_{UT} težina kriterija udaljenosti od trgovina, W_{UGD} težina kriterija udaljenosti od glavnih dobavljača i W_{FK} težina kriterija fleksibilnosti kretanja.

Rangiranje prioriteta skladišta dobivenih AHP metodom u ovom diplomskom radu, zajedno s rangiranjem prioriteta skladišta preuzetim iz znanstvenog članka koji su dobiveni metodama TOPSIS, ELECTRE i *grey theory*, prikazano je u tablici 6.

Tablica 6. Rangiranje ukupnih prioriteta alternativa ovisno o metodi [5]


	AHP	TOPSIS	ELECTRE	Grey theory
SKLADIŠTE A	4	4	3	4
SKLADIŠTE B	3	3	2	2
SKLADIŠTE C	2	2	2	1
SKLADIŠTE D	1	1	1	3

Rezultati dobiveni AHP metodom u ovom diplomskom radu se podudaraju s rezultatima iz znanstvenog članka dobivenih TOPSIS metodom, a vrlo su slični rezultatima ELECTRE metode, unatoč razlici algoritama za izračun metodologija odlučivanja. Rezultati dobiveni metodom *grey theory* razlikuju se od ostalih [Tablica 6].

S obzirom na to da su dobiveni rezultati gotovo identični za većinu metoda, postavlja se pitanje koliko zapravo relativne važnosti (težine) kriterija utječu na ukupne prioritete alternativa. Softverski alat *expert choice* sadrži idealnu opciju koja trenutno daje odgovor na postavljeno pitanje. Navedena opcija zove se analiza osjetljivosti rezultata, a odabire se


otvaranjem padajućeg izbornika *Sensitivity-Graphs*. Postoje tri grafa u kojima se može provesti analiza osjetljivosti rezultata: graf performansi (*Performance*), graf dinamičnosti (*Dynamic*) i graf gradijenta (*Gradient*).

Analiza osjetljivosti rezultata putem grafa dinamičnosti prikazana je na slici 38.. Relativne važnosti (težine) kriterija se jednostavno mijenjaju kako bi se vidio njihov utjecaj na konačne prioritete alternativa. Mijenjanjem težine jednog kriterija, ostale se mijenjaju proporcionalno. Kad bi težine kriterija iznosile $\{W_C, W_{KS}, W_{UT}, W_{UGD}, W_{FK}\} \approx (0.2, 0.1, 0.32, 0.32, 0.06)$ prioriteti alternativa bi se promijenili, te bi se za najbolju alternativu dobilo skladište B. Iza njega slijedilo bi skladište D i skladište C s malom razlikom u prioritetu, te na kraju skladište A.




Slika 38. Graf dinamičnosti

Na slici 39. prikazuje se analiza osjetljivosti rezultata putem grafa performansi. Ovaj graf prikazuje slične podatke kao i graf dinamičnosti, samo na drugačiji način. Relativne važnosti (težine) kriterija se jednostavno mijenjaju kako bi se vidio njihov utjecaj na konačne prioritete alternativa. Na desnoj strani se prikazuju trenutni prioriteti alternativa dok položaj tih linija daje uvid u redoslijed konačnih prioriteta alternativa s obzirom na težinu pojedinog kriterija. Na primjer, kada bi kriterij prosječna udaljenost od trgovina imao težinu 0.55 ili više, ukupni prioriteti alternativa bi bili poredani ovim redoslijedom: skladište B, skladište C, skladište D, skladište A.



Slika 39. Graf performansi

Na slici 40. prikazuje se analiza osjetljivosti putem grafa gradijenta s obzirom na kriterij prosječna udaljenost od trgovina. Uz pomoć ove opcije softver omogućuje da se vidi koliko su prioriteti alternativa osjetljivi na promjene težina pojedinih kriterija. Vertikalna crvena linija prikazuje težinu kriterija dobivenu nakon usporedbe prema Saatyjevoj skali, dok isprekidana plava linija prikazuje trenutno odabranu težinu kriterija. S desne strane prikazuju se ukupni prioriteti alternativa za trenutno odabranu težinu kriterija. Na slici se može vidjeti da prioriteti skladišta B i C rastu s porastom težine kriterija prosječna udaljenost od trgovina, dok prioriteti skladišta D i A opadaju.



Slika 40. Graf gradijenta s obzirom na prosječnu udaljenost od trgovina

7. ZAKLJUČAK

Kako bi se dobili optimalni rezultati u odabiru lokacije skladišta, potrebno je definirati kriterije isključivo prema problemu s kojim se donositelj odluke susreće. Teško je promatrati problem lokacije skladišta općenito, obzirom da se kriteriji razlikuju od slučaja do slučaja. Na primjer, ako se traži lokacija skladišta humanitarne pomoći, kao kriterij će se obavezno uvrstiti kooperacija s Ujedinjenim narodima, nevladinim organizacijama, itd. ili ako se traži lokacija skladišta na područjima prirodnih katastrofa, kao važan kriterij će se uvrstiti prostorna udaljenost od žarišta katastrofe. Iako su u prethodnim slučajevima navedeni kriteriji vrlo važni, ipak u većini slučajeva oni neće imati nikakvu ulogu pri određivanju lokacije skladišta. Ako postoji samo jedan kriterij u odabiru lokacije skladišta, a to je smanjenje prijednog puta odnosno troškova, koriste se kvantitativni modeli. Ako pak postoji više kriterija, koristi se višekriterijalno odlučivanje.

Postoje brojne različite metode višekriterijalnog odlučivanja, međutim u odabiru lokacije skladišta svoju primjenu su našle samo neke od njih: AHP, *fuzzy* AHP, ELECTRE, TOPSIS, *fuzzy* TOPSIS, PROMETHEE i *grey theory*. U ovom diplomskom radu, za izbor lokacije skladišta, odabrana je AHP metoda.

Primjer za odabir lokacije skladišta preuzet je iz znanstvenog članka [5] u kojem se na isti primijenila TOPSIS, ELECTRE i *grey theory*. Relativne važnosti (težine) kriterija korištenih u navedenim metodama su gotovo identične $\{W_C, W_{KS}, W_{UT}, W_{UGD}, W_{FK}\} \approx (0.29, 0.35, 0.15, 0.15, 0.06)$. Rezultati dobiveni AHP metodom u ovom diplomskom radu se podudaraju s rezultatima iz znanstvenog članka [5] dobivenih TOPSIS metodom, a vrlo su slični rezultatima ELECTRE metode, unatoč razlici algoritama za izračun metodologija odlučivanja. Rezultati dobiveni metodom *grey theory* razlikuju se od ostalih [Tablica 6].

Iz prethodnog se može zaključiti kako su rezultati dobiveni AHP, TOPSIS i ELECTRE metodom jako slični jer su korištenjem ovih metoda relativne važnosti (težine) alternativa u odnosu na kriterije, procijenjene paralelno s dvije osnovne namjene: maksimizacijom i minimizacijom. Na primjer, kod određivanja najznačajnije alternative s obzirom na kapacitet skladišta, dobivena je ona s najvećim kapacitetom skladišta odnosno skladište D. Poznavajući problematiku, mali kapacitet skladišta može izazvati probleme u slučaju porasta zahtjeva skladištenja, dok veliki kapacitet skladišta može izazvati prazan

prostor a samim time i veće troškove skladišnog prostora, optimalno skladište bi trebalo imati srednji kapacitet.

Rezultati dobiveni metodom *grey theory* drugačiji su zbog razlike u formulama koje se koriste u fazi standardizacije relativnih važnosti (prioriteta) alternativa u odnosu na kriterije. Na primjer, korištenjem metode *grey theory*, kao najbolja alternativa s obzirom na kapacitet skladišta, dobivena je ona najbliža srednjem kapacitetu, odnosno skladište C.

Postoje mnoge prednosti rješavanja primjera u softverskom alatu *expert choice* od klasičnog računanja AHP metodom. Osim brzine, velika prednost je u točnosti rezultata koji kod klasičnog načina mogu biti upitni, ako je došlo do pogreške u računanju. Osim navedenog, najveća prednost rješavanja primjera u softverskom alatu *expert choice* je mogućnost analize osjetljivosti rezultata. Na jednostavan način mogu se promijeniti relativne važnosti (težine) kriterija i vidjeti kako one ustvari uvelike utječu na ukupne prioritete alternativa, odnosno krajnje rezultate.

LITERATURA

- [1] Heragu, S. S.: Facilities Design, Rensselaer Polytechnic Institute, PWS Publishing Company, 1997.
- [2] Demirel, T., Demirel, N. C., and Kahraman, C.: Multi-criteria warehouse location selection using Choquet integral, Expert Systems with Applications, Vol. 37, Elsevier, 2010.
- [3] Ashrafzadeh, M., Rafiei, F. M., and Zare, Z.: The Application of Fuzzy Analytic Hierarchy Process Approach for the Selection of Warehouse Location: A Case Study, International Journal of Business and Social Science, Vol. 3, No. 4, 2012.
- [4] Brandeau, M. L., and Chiu, S. S.: An overview of representative problems in location research, Management Science, Vol. 35, No. 6, 1989.
- [5] Ozcan, T., Celebi, N., Esnaf, S.: Comparative Analysis of multi-criteria decision making methodologies and implementation of a warehouse location selection problem, Expert Systems with Applications, Vol. 38, Elsevier, 2011.
- [6] Degener, P., Gosling, H., Geldermann, J.: Decision support for the location planning in disaster areas using multi-criteria methods, Proceedings of the 10th International ISCRAM Conference, 2013.
- [7] Roh, S., Jang, H., Han, C.: Warehouse Location Decision Factors in Humanitarian Relief Logistics, The Asian Journal of Shipping and Logistics, Vol. 29, No. 1, 2013.
- [8] Awasthi, A., Chauhan, S. S., Goyal, S. K.: A multi-criteria decision making approach for location planning for urban distribution centers under uncertainty, Mathematical and Computer Modelling, Vol. 53, Elsevier, 2011.
- [9] Aruldoss, M., Lakshmi, M., T., Venkatesan, P., V.: A Survey on Multi Criteria Decision Making Methods and Its Applications, American Journal of Information Systems, Vol. 1, No. 1, Science and Education Publishing, 2013.
- [10] Xu, L., Yang, J.: Introduction to Multi-Criteria Decision Making and the Evidential Reasoning Approach, University of Manchester Institute of Science and Technology, 2001.
- [11] Velasquez, M., Hester, P., T.: An Analysis of Multi-Criteria Decision Making Methods, International Journal of Operations Research, Vol. 10, No. 2, 2013.

- [12] Chakraborty, R., Ray, A., Dan, P., K.: Multi criteria decision making methods for location selection of distribution centers, *International Journal of Industrial Engineering Computations*, Vol. 4, 2013.
- [13] Koksalan, M., Wallenius, J., Zionts, S.: *Multiple Criteria Decision Making: From Early History to the 21st Century*, World Scientific Publishing Co. Pte. Ltd., 2011.
- [14] Li, G., D., Yamaguchi, D., Nagai, M.: A Grey based Approach to Suppliers Selection Problem, *Proceedings of the International Conference on Parallel and Distributed Processing Techniques and Applications*, Vol. 2, 2006.
- [15] Saaty, T. L.: *The Analytic Hierarchy Process: Planning, Priority Setting, Resource Allocation*, McGraw-Hill, 1980
- [16] Klanac, J., Perkovic, J., Krajnović, A.: *Primjena AHP i PROMETHEE metode na problem diverzifikacije*, Oeconomica Jadertina, 2013.
- [17] Forman, E., Selly, M., A.: *Decision By Objectives (How to convince others that you are right)*
- [18] Lisjak, D.: *Primjena AHP-metode kao alata za optimalni izbor opreme*, Zagreb, 2011.
- [19] <http://expertchoice.com/>
- [20] Millet, I., Saaty, T., L.: *On the Relativity of Relative Measures - Accommodating both Rank Preservation and Rank Reversals in the AHP*, 1998

PRILOZI

I. CD-R disc